

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ  
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION  
DEPARTMENT OF BIOMEDICAL ENGINEERING


TEXTURNÍ ANALÝZA SNÍMKŮ SÍTNICE SE ZAMĚŘENÍM  
NA DETEKCI NERVOVÝCH VLÁKEN

DIPLOMOVÁ PRÁCE  
MASTER'S THESIS


AUTOR PRÁCE  
AUTHOR

Bc. JIŘÍ GAZÁREK

BRNO 2008



VYSOKÉ UČENÍ TECHnickÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY  
A KOMUNIKAČNÍCH TECHNOLOGIÍ  
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND  
COMMUNICATION  
DEPARTMENT OF BIOMEDICAL ENGINEERING

## TEXTURNÍ ANALÝZA SNÍMKŮ SÍTNICE SE ZAMĚŘENÍM NA DETEKCI NERVOVÝCH VLÁKEN

TEXTURE ANALYSIS OF RETINAL IMAGES ORIENTED TOWARDS DETECTION  
OF NERONAL FIBRE LAYER

DIPLOMOVÁ PRÁCE  
MASTER'S THESIS

AUTOR PRÁCE  
AUTHOR

Bc. Jiří GAZÁREK

VEDOUCÍ PRÁCE  
SUPERVISOR

prof. Ing. Jiří Jan, CSc.

BRNO 2008

ZDE VLOŽIT LIST ZADÁNÍ

Z důvodu správného číslování stránek

ZDE VLOŽIT PRVNÍ LIST LICENČNÍ  
SMOUVY

Z důvodu správného číslování stránek

ZDE VLOŽIT DRUHÝ LIST LICENČNÍ  
SMOUVY

## **ABSTRAKT**

Práce je zaměřena na detekci fokálního výpadku ve vrstvě nervových vláken na snímcích sítnice pořízených fundus kamerou. První kapitola popisuje fyziologii lidského oka, glaukomové onemocnění a analyzovaná data. Druhá kapitola porovnává čtyři odlišné přístupy, které by mohly být použity k automatické detekci možného výpadku ve vrstvě nervových vláken. Tyto čtyři přístupy byly testovány a vyhodnoceny; tři z nich vykazují přijatelnou shodu se snímky označenými oftalmologem – jedná se o přístupy vycházející z metody směrové spektrální analýzy, metody odvozené z hranové reprezentace a metody hodnocení jasů. Poslední přístup založený na maticích co-occurrence se neukázal jako vhodný k řešení zadaného problému. Součástí této práce byl také návrh realizace a hodnocení programu pro automatickou detekci oblastí s výpadkem nervových vláken. Tomuto problému je věnována poslední kapitola. Bylo dosaženo poměrně dobrých výsledků při porovnání výstupů programu s oblastmi označenými oftalmologem.

## **KLÍČOVÁ SLOVA**

texturní analýza, glaukom, výpadek ve vrstvě nervových vláken, co-occurrence matice, směrová spektrální analýza, detekce hran

## **ABSTRACT**

The thesis is focused on detection of local disappearance of the neural layer on retina in fundus-camera images. The first chapter describes the human eye physiology, the glaucoma disease and the analyzed data. The second chapter compares four different approaches that should enable automatic detection of a possible damage to the retinal neural layer. These four approaches have been tested and evaluated; three of them showed an acceptable correlation with the medical expert conclusions – the directional spectral approach, the edge based approach and the difference local brightness. The last approach via local co-occurrence matrices has not turned out to be informative with the respect to the issue concerned. Then a program for the automatic detection of the nerve fibre layer loss areas has been designed, realized and evaluated. This task is solved in the last chapter. A relatively good agreement between the medical expert conclusions and the conclusions detected automatically by this program has been reached.

## **KEYWORDS**

texture analysis, glaucoma, nerve fibre layer loss, co-occurrence matrix, directional spectral analysis, edge-based detection

GAZÁREK J. *Texturní analýza snímků sítnice se zaměřením na detekci nervových vláken*. Brno: Vysoké učení technické v Brně. Fakulta elektroniky a komunikačních technologií. Ústav biomedicínského inženýrství, 2008. Počet stran 88, počet stran příloh 15. Diplomová práce. Vedoucí práce byl prof. Ing. Jiří Jan, CSc.

## PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Texturní analýza snímků sítnice se zaměřením na detekci nervových vláken“ jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne .....

.....  
(podpis autora)



Sem lze vložit poděkování

Není však nutné

# Obsah

Úvod	15
<b>1 ANATOMIE OKA, VSTUPNÍ DATA</b>	<b>16</b>
1.1 Fyziologie lidského oka se zaměřením na nervová vlákna	16
1.1.1 Glaukom	17
Glaukomové poškození	17
Změny na sítnici probíhající při glaukomovém poškození	18
1.2 Zpracovávaná data	20
1.2.1 Popis snímání dat	20
1.2.2 Rozdělení snímků z hlediska uložení dat	21
Nekomprimovaná RAW data	21
Komprimované snímky <i>jpg</i>	21
<b>2 TEXTURNÍ ANALÝZA</b>	<b>23</b>
2.1 Teoretický úvod	23
2.1.1 Metody texturní analýzy	23
Statistiky prvního řádu	23
Statistiky druhého řádu	24
2.1.2 Statistické testy	26
Test významnosti rozdílu mezi dvěma rozptyly – F-test	26
Test významnosti rozdílu dvou výběrových průměrů	26
2.2 Analýza metodou matice co-occurrence	27
2.2.1 Návrh programu	27
Vstupní parametry programu	27
Vytvoření oblasti zájmu	27
Výpočet matice co-occurrence pro různé směry	28
Výpočet příznaků z co-occurrence matice	30
Umístění příznaku do matice příznaků	31
2.2.2 Výběr testovacích textur	31
2.2.3 Analýza testovacích textur	34
2.2.4 Srovnání matic co-occurrence a jejich jednotlivých příznaků	36
Srovnání matic co-occurrence zdravých tkání s tkáněmi s vý-	
padkem	36
Srovnání jednotlivých příznaků matic co-occurrence	37
2.2.5 Hodnocení funkčnosti metody	38
2.3 Spektrální analýza	39
2.3.1 Teoretický úvod	39

2.3.2	Výběr oblastí zájmu pro spektrální analýzu . . . . .	39
2.3.3	Návrh programu pro metodu směrové spektrální analýzy . . .	40
	Návrh části programu pro tvorbu výsečí spektra . . . . .	41
2.3.4	Porovnání výsledků . . . . .	45
2.3.5	Hodnocení funkčnosti metody . . . . .	45
2.4	Metoda vycházející z hranové reprezentace . . . . .	46
2.4.1	Teoretický úvod . . . . .	46
2.4.2	Návrh programu . . . . .	46
2.4.3	Porovnání výsledků . . . . .	48
	Statistika celé oblasti zájmu . . . . .	48
	Statistika ve vybraných oblastech . . . . .	49
2.4.4	Hodnocení funkčnosti metody . . . . .	49
2.5	Metoda hodnocení jasů . . . . .	50
2.5.1	Teoretický úvod . . . . .	50
2.5.2	Návrh programu . . . . .	50
2.5.3	Hodnocení funkčnosti metody . . . . .	50

### **3 PROGRAM PRO AUTOMATICKOU DETEKCI OBLASTÍ VÝ- PADKU NERVOVÝCH VLÁKEN 51**

3.1	Návrh programu . . . . .	51
3.1.1	Segmentace a vymaskování cévního řečiště . . . . .	51
	Segmentace cévního řečiště . . . . .	51
	Vymaskování cévního řečiště . . . . .	53
3.1.2	Automatická detekce oblasti zájmu . . . . .	55
3.1.3	Určení kroku analýzy, značení cév a oblastí s vysokým podílem neurčitosti . . . . .	55
3.1.4	Automatická detekce výpadku ve vrstvě nervových vláken . .	56
3.2	Manuál k programu . . . . .	58
3.2.1	Nastavení jednotlivých kroků analýzy . . . . .	59
	Nastavení celkové analýzy . . . . .	59
	Nastavení segmentace cév . . . . .	60
	Nastavení vymaskování cév . . . . .	60
	Nastavení pro výběr oblasti zájmu . . . . .	61
	Nastavení spektrální analýzy . . . . .	63
	Nastavení analýzy jasů . . . . .	64
	Nastavení hranové detekce pomocí LoG . . . . .	64

<b>4</b>	<b>VÝSLEDKY DETEKCE OBLASTÍ VÝPADKU VE VRSTVĚ NERVOVÝCH VLÁKEN</b>	<b>66</b>
4.1	Diskuze k výsledkům . . . . .	70
<b>5</b>	<b>Závěr</b>	<b>71</b>
	<b>Literatura</b>	<b>72</b>
	<b>Seznam příloh</b>	<b>73</b>
<b>A</b>	<b>Tabulky</b>	<b>74</b>
A.1	Tabulky pro cooc . . . . .	74
A.2	Rozdíly energií u spektrální analýzy . . . . .	76
A.3	Tabulky pro metodu hranové reprezentace . . . . .	78
<b>B</b>	<b>Zdrojové kódy</b>	<b>79</b>
B.1	Výchozí nastavení vstupních proměnných . . . . .	79
B.2	Funkce pro celkovou analýzu . . . . .	80
B.2.1	Funkce pro značení cév . . . . .	82
B.3	Funkce pro vytvoření výsečí pro směrovou spektrální analýzu . . . . .	83
B.4	Funkce pro výpočet směrové spektrální analýzy . . . . .	84
B.5	Funkce pro výpočet metody založené na hranové reprezentaci . . . . .	85
B.6	Funkce pro výpočet analýzy jasu . . . . .	86
<b>C</b>	<b>Obrazová příloha</b>	<b>87</b>
C.1	Ukázka vzhledu hlavního menu navrženého programu . . . . .	87
C.2	Schéma programu pro RGB snímek . . . . .	88

# Seznam obrázků

1.1	a) Sítnice, b) Histologický řez sítnicí . . . . .	16
1.2	Nervová vlákna sbíhající se ve zrakový nerv (terč zrakového nervu) . .	16
1.3	Retinální snímek, směr nervových vláken je znázorněn červeně . . . .	17
1.4	Ztráta nervových vláken a postup exkavace v důsledku zvýšeného nitroočního tlaku . . . . .	18
1.5	Retinální snímek z fundus kamery s vyznačenou oblastí výpadku . . .	18
1.6	Detail výpadku na sítnici na snímku pořízeném fundus kamerou . . .	19
1.7	Glaukomová exkavace . . . . .	19
1.8	Přenosová funkce filtru BPB45 . . . . .	20
1.9	Porovnání celobarevného RGB snímku se snímkem snímaným přes filtr	21
1.10	Porovnání jednotlivých složek celobarevného RGB snímku se složkami snímku snímaného přes filtr . . . . .	22
2.1	Možné směry výpočtu matice co-occurrence . . . . .	24
2.2	Popis posunu okna po obraze . . . . .	28
2.3	Levé oko: Výchozí obraz se zobrazením výpadku nervových vláken . .	32
2.4	Levé oko: upravený obraz s vyznačenými výřezy . . . . .	32
2.5	Pravé oko: Výchozí obraz se zobrazením výpadku nervových vláken .	33
2.6	Pravé oko: upravený obraz s vyznačenými výřezy . . . . .	33
2.7	Profil intenzity texturami s názvem <i>zdravé01</i> a <i>zdravé02</i> . . . . .	34
2.8	Profil intenzity texturami s názvem <i>zdravé03</i> a <i>zdravé04</i> . . . . .	34
2.9	Profil intenzity texturami s názvem <i>zdravé05</i> a <i>výpadek06</i> . . . . .	35
2.10	Profil intenzity texturami s názvem <i>výpadek07</i> a <i>výpadek08</i> . . . . .	35
2.11	Profil intenzity texturami s názvem <i>výpadek09</i> a <i>výpadek10</i> . . . . .	35
2.12	Matice co-occurrence pro texturu s názvem <i>zdravé02</i> pro různé směry	36
2.13	Obrazy matic příznaků energie pro různé velikosti okna . . . . .	37
2.14	Ukázka spekter tkání s výpadkem ve vrstvě nervových vláken a spek- ter zdravých tkání . . . . .	40
2.15	Ukázka postupné rotace výseče. Vyobrazeny první 4 kroky z celkových 22 kroků. . . . .	42
2.16	Mezikruží pro výběr relevantních hodnot ze spektra . . . . .	43
2.17	Ukázka fungování metody vycházející z hranové reprezentace . . . .	47
3.1	Porovnání kvality segmentace u RGB snímku a snímku snímaného přes filtr . . . . .	52
3.2	Ukázka vymaskování cévního řečiště metodou nejbližšího souseda . .	54
3.3	Oblast zájmu a detail celkové analýzy . . . . .	56
3.4	vysvětlení k zobrazení výsledků detekce v obr.3.3b . . . . .	57
3.5	Schématické znázornění rozložení pracovní plochy . . . . .	58

3.6	Menu nastavení pro celkovou analýzu snímku . . . . .	59
3.7	Menu nastavení pro segmentaci cév . . . . .	60
3.8	Menu nastavení pro vymaskování cév . . . . .	61
3.9	Menu nastavení pro výběr oblasti zájmu . . . . .	62
3.10	Znázornění způsobu vytvoření oblasti zájmu pro analýzu . . . . .	62
3.11	Menu nastavení pro spektrální analýzu . . . . .	63
3.12	Menu nastavení pro analýzu jasu . . . . .	64
3.13	Ovládací panel pro nastavení analýzy vycházející z hranové reprezentace	65
4.1	Ukázka výsledné detekce u snímku zdravého pacienta . . . . .	66
4.2	Snímek s názvem 1B s vyznačením výpadu ve vrstvě nervových vláken oftalmologem . . . . .	67
4.3	Snímek s názvem 1B s vyznačením výpadu ve vrstvě nervových vláken automatickou detekcí . . . . .	67
4.4	Snímek s názvem 3B s vyznačením výpadu ve vrstvě nervových vláken oftalmologem . . . . .	68
4.5	Snímek s názvem 3B s vyznačením výpadu ve vrstvě nervových vláken automatickou detekcí . . . . .	68
4.6	Snímek s názvem 4B s vyznačením výpadu ve vrstvě nervových vláken oftalmologem . . . . .	69
4.7	Snímek s názvem 4B s vyznačením výpadu ve vrstvě nervových vláken automatickou detekcí . . . . .	69

# Seznam tabulek

2.1	Maximální rozdíly energií u 15° výsečí 2D spekter testovacích textur .	45
2.2	Výsledky t-testu pro jednotlivé typy testu. . . . .	45
2.3	Procentuální zastoupení detekovaných hran u snímku obsahující vý- padek ve vrstvě nervových vláken . . . . .	48
2.4	Procentuální zastoupení detekovaných hran u snímku zdravého oka .	48
2.5	Výsledná prostorová hustota detekovaných hran . . . . .	49
A.1	Hodnoty průměrných energií vypočtených pomocí matic co - occurrence	74
A.2	Hodnoty entropií a kontrastů vypočtených pomocí matic co - occurrence	75
A.3	Maximální rozdíly energií u 22,5° výsečí 2D spekter testovacích textur z oblastí výpadku nervových vláken . . . . .	76
A.4	Maximální rozdíly energií u 22,5° výsečí 2D spekter testovacích textur z oblastí zdravých tkání u nemocných očí . . . . .	77
A.5	Maximální rozdíly energií u 22,5° výsečí 2D spekter testovacích textur zdravých očí . . . . .	77
A.6	Počty pixelů detekovaných jako hrana u výřezů textur obsahujících výpadek ve vrstvě nervových vláken – skupina A . . . . .	78
A.7	Počty pixelů detekovaných jako hrana u tkání obsahujících nervová vlákna u nemocných očí – skupina B . . . . .	78
A.8	Počty pixelů detekovaných jako hrana u tkání obsahujících nervová vlákna u zdravých očí – skupina C . . . . .	78

# Úvod

S rozvojem moderních diagnostických metod<sup>1</sup> by se mohlo zdát, že se vyšetření fundus kamerou pomalu vytratí. Nové diagnostické metody jsou však stále nákladné a na rozdíl od fundus kamer nejsou na oftalmologických pracovištích zdaleka tak rozšířené. Z tohoto důvodu a také díky vývoji moderních digitálních fundus kamer se během posledních let zájem o fundus kamery opět zvýšil.

V obrazech sítnice má diagnosticky největší význam hlavně detekce cévního řečiště, žluté skvrny, optického disku a v poslední době se vyvíjejí i metody segmentace vrstvy nervových vláken, které mohou přispět k včasné diagnostice glaukomového poškození. Právě detekcí oblastí nervových vláken v oftalmologických obrazech pořízených digitální fundus kamerou se zabývá tato diplomová práce. Prací zaměřených na tuto problematiku se příliš mnoho nalézt nepodařilo. Navíc tyto práce používají jiné přístupy. Jedná převážně o popisy matematických postupů pro detekci vrstvy nervových vláken. Jejich výsledky však zůstávají na úrovni základního výzkumu, bez praktické aplikace.

Cílem práce bylo prostudovat a zhodnotit metody texturní analýzy se zaměřením na příznakové metody ve spektrální oblasti a metody lokálních statistik. Byly navrženy různé přístupy pro lokální detekci nervové vrstvy a bylo ověřeno, které kombinace metod se jeví jako perspektivní pro případné rutinní použití.

Jako vstupní data pro analýzu posloužily oftalmologické obrazy pořízené fundus kamerou CANON CF-60 UVi s vestavěným digitálním fotoaparátem CANON EOS-20D z databáze dostupné na ÚBMI FEKT VUT v Brně, pocházejících z oftalmologické ordinace MUDr. Tomáše Kuběny.

Konečným výsledkem práce je rutinně použitelný program sloužící pro automatickou detekci oblastí výpadku nervových vláken. Program je doložen komentovanými výpisy programů, které jsou přiloženy na CD. Veškeré navržené aplikace v této diplomové práci vznikly ve vývojovém prostředí MATLAB verze R2006a.

---

<sup>1</sup>např. laserová skenovací polarimetre (GDx), optická koherentní tomografie (OCT)



# 1 ANATOMIE OKA, VSTUPNÍ DATA


## 1.1 Fyziologie lidského oka se zaměřením na nervová vlákna

Sítnice převádí světelnou informaci na nervové impulzy. Sítnice je složena z několika vrstev (viz obr. 1.1), z nichž nejzvnějšší obsahuje fotosenzitivní receptory. Ty předávají informaci další vrstvě, složené z bipolárních buněk. Odtud je informace předávána dál směrem k nejvnitřnější vrstvě sítnice, která je složena z gangliových buněk. Výběžky těchto nervových gangliových buněk, takzvané axony, opouštějí oko v terči zrakového nervu (zvaném také papila) a vedou přímo do mozku (viz obr. 1.2).



Obr. 1.1: a) Sítnice (žlutě), b) Histologický řez sítnicí: 1 – gangliové buňky, 2 – bipolární buňky, 3 – jádra receptorových buněk, 4 – axony receptorových buněk [2]


Sítnice informaci nejenom přijímá a přenáší, ale také ji předem zpracovává. Aby to bylo možné, je nutné složité propojení mezi buňkami. Ve zdravém oku je přibližně 132 milionů receptorových buněk, přibližně 1 milion gangliových buněk a tedy i 1 milion nervových vláken, která vedou z terče zrakového nervu do mozku.



Obr. 1.2: Nervová vlákna se sbíhají ve zrakový nerv, který oko opouští v místě zvaném terč zrakového nervu [2]

Na rozdíl od zrakového nervu nemají nervová vlákna sítnice myelin, speciální ochrannou a izolační vrstvu. Kdyby ji měly, tak by nemohly řádně plnit svoji funkci v procesu vidění, pro který je transparentnost zásadní. Jednoduše řečeno: světlo se musí dostat vrstvou nervových vláken k fotoreceptorům, aniž by mu něco stálo v cestě. Terč zrakového nervu je také bez myelinu, ne protože by tu také byla nutná transparentnost, ale spíše kvůli omezenému prostoru na kribróze (kribróza – oblast s drobnými otvory, kterými nervová vlákna opouštějí oko). Z toho důvodu jsou nervová vlákna zranitelná.

Nervová vlákna se nachází ve vnitřní vrstvě sítnice, a jak je patrné z obr. 1.2 a obr. 1.3, sbíhají se ve zrakový nerv, který oko opouští v místě zvaném terč zrakového nervu.



Obr. 1.3: Retinální snímek, směr nervových vláken je znázorněn červeně


### 1.1.1 Glaukom

Glaukom je skupina onemocnění, která jsou často spojena se zvýšeným nitroočním tlakem. Vzniká při něm ztráta nervových buněk sítnice a jeho vláken (které tvoří zrakový nerv). V důsledku toho se vytvářejí v zorném poli defekty, které pacient z počátku nepozoruje. Pro léčbu je zcela zásadní včasné odhalení glaukomu.

#### Glaukomové poškození

Při glaukomu nervové buňky a nervová vlákna postupně odumírají. V důsledku toho se také postupně narušuje spojení mezi okem a mozkem, které je pro proces vidění zásadní. Oko stále detekuje světlo, protože tyčinky a čípky stále pracují, ale přenos zrakové informace do mozku je přerušeno. Toto je podstata problému a je označována jako „glaukomové poškození“. U glaukomu dochází zejména ke ztrátám gangliových

buněk sítnice. Všechny detaily tohoto procesu nejsou v současnosti známy, jsou však známy některé faktory zvyšující pravděpodobnost rozvoje glaukomového poškození. Existují rizikové faktory, které je možno ovlivnit, jako například zvýšený nitrooční tlak, nízký systémový tlak a dysregulace krevních cév. Jsou ale i rizikové faktory, které kontrolovat nelze, jako věk, pohlaví, refrakční vady atd. Většina odborníků považuje za hlavní příčinu vzniku glaukomu především zvýšený nitrooční tlak.




Obr. 1.4: Ztráta nervových vláken a postup exkavace v důsledku zvýšeného nitroočního tlaku

### Změny na sítnici probíhající při glaukomovém poškození


**Ztráta nervových vláken** – při glaukomu mohou být postižena jednotlivá nervová vlákna sítnice nebo dokonce celé svazky těchto vláken. Tento stav se nazývá výpadek svazku nervových vláken. Během života dochází dokonce i za normálních okolností denně ke ztrátám gangliových buněk a jejich axonů. V důsledku nemoci však dochází u pacientů s glaukomovým onemocněním k mnohem rychlejšímu úbytku gangliových buněk a nervových vláken.

Na retinálním snímku z fundus kamery se fokální výpadek jeví jako „tmavý vějíř komety“, viz obr. 1.5.



Obr. 1.5: Retinální snímek z fundus kamery s vyznačenou oblastí výpadku

V oblastech, kde jsou nervová vlákna zachována, je většinou na snímku patrné jemné proužkování (žíhání). V místě výpadku je sítnice tmavší, bez proužkování. Na obr. 1.6 znázorňuje červená šipka výpadek ve vrstvě nervových vláken.




Obr. 1.6: Detail výpadku na sítnici na snímku pořízeném fundus kamerou

**Glaukomová ztráta tkáně** – ztráta tkáně se obecně nazývá atrofie. Atrfie papily (optického terče) je částečný nebo úplný zánik nervových vláken tvořících zrakový nerv. Atrfie papily se dělí podle příčin na prostou a glaukomovou.

Pro prostou atrofii papily je charakteristická ztráta nervových vláken bez ztráty ostatních tkání, které tvoří papilu. K příčinám prosté atrofie papily se řadí úrazy, u nichž je přerušen zrakový nerv, některá dědičná onemocnění a nedostatek některých vitamínů.

Pro glaukomovou atrofii papily je typické vytváření vyhloubení (exkavace) na terči zrakového nervu (viz obr. 1.7). Kromě odumírajících nervových buněk dochází ke ztrátě podpurných gliálních buněk a krevních cév.




Obr. 1.7: V důsledku ztráty nervových vláken a gliálních buněk vzniká glaukomová exkavace

## 1.2 Zpracovávaná data

### 1.2.1 Popis snímání dat

Veškeré snímky použité v této práci byly pořízeny pomocí fundus kamery CANON CF-60 UVi s vestavěným digitálním fotoaparátem CANON EOS-20D. Velikost snímaného zorného pole byla 60°. Snímky byly exponovány při bílém zdroji světla za použití xenonové výbojky. Byly pořízeny dva druhy snímků. Prvním druhem je celobarevný snímek (tzv. RGB snímek). Druhý druh snímků byl snímán za použití zeleného filtru s označením BPB45. Tento filtr vykazuje maximum na vlnové délce 450nm a potlačuje světelné spektrum odpovídající červené oblasti (jeho charakteristika je na obr. 1.8).




Obr. 1.8: Přenosová funkce filtru BPB45

Jak je patrné z obr. 1.10, jednotlivé složky se navzájem u celobarevného snímku a snímku snímaného přes filtr podstatně liší. R složka je u snímku snímaného přes filtr prakticky odfiltrována, zbylé G a B složky jsou u tohoto typu snímku téměř totožné a jeví se podobně, jako sloučené složky G a B u celobarevného RGB snímku podle vzorce 1.1. Pro pokus o přesnější rekonstrukci bychom potřebovali charakteristiku snímače fotoaparátu, kterou se nám avšak nepodařilo získat.

$$g(i, j) = \frac{1}{2} \left( f_g(i, j) + f_b(i, j) \right) \quad (1.1)$$

Porovnáním sloučených GB složek celobarevného snímku a snímku snímaného přes filtr lze konstatovat, že se jeví subjektivně podobně, avšak shodné nejsou. Cévy jsou zřetelnější u GB složky z RGB snímku, nervová vlákna naopak u GB složky snímku snímaného přes filtr.





Obr. 1.9: Porovnání celobarevného RGB snímku se snímkem snímaným přes filtr,  
a) RGB snímek, b) snímek snímaný přes filtr

### 1.2.2 Rozdělení snímků z hlediska uložení dat

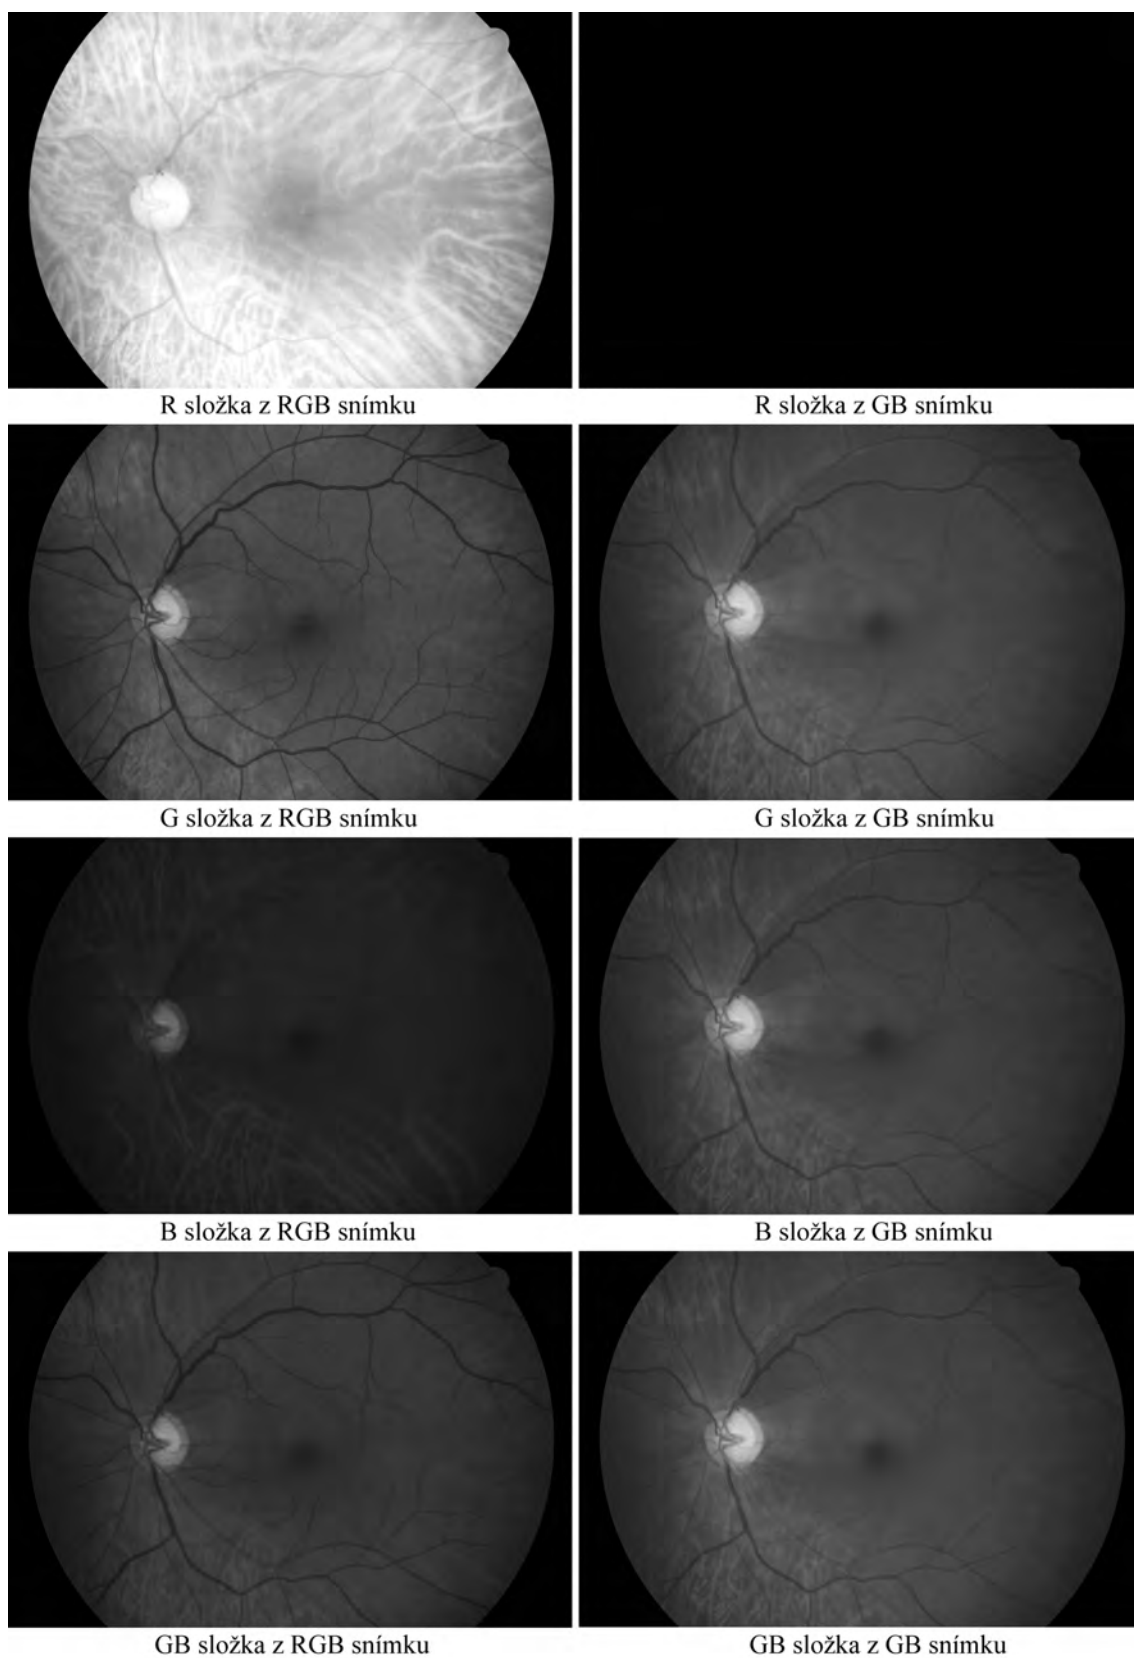
Pro naši práci jsme měli k dispozici dva druhy formátů snímků. Komprimované snímky ve formátu *\*.jpg* a dále nekomprimovaná surová RAW data ve formátu *\*.cr2*.

#### Nekomprimovaná RAW data

Jeden výsledný pixel u surových RAW dat je tvořen ze čtyř elementárních složek: červenou *R* složkou, modrou *B* a dvěma zelenými *G* složkami. Jednotlivé složky RAW dat mají velikost  $1174 \times 1761$  pixelů. Tyto snímky byly použity při texturní analýze pomocí metody co-occurrence matice, viz kap. 2.2.

#### Komprimované snímky *jpg*

Tyto snímky mají rozlišení  $2336 \times 3504$  pixelů. Tyto snímky byly použity pro analýzu ve všech kapitolách kromě kap. 2.2.



Obr. 1.10: Porovnání jednotlivých složek celobarevného RGB snímku se složkami snímku snímaného přes filtr

## 2 TEXTURNÍ ANALÝZA

### 2.1 Teoretický úvod

#### 2.1.1 Metody texturní analýzy

##### Statistiky prvního řádu

Tyto statistiky závisí podle [3] pouze na hodnotě šedi daného pixelu, nikoliv na interakci nebo součtu výskytu této hodnoty v okolí daného pixelu. Tyto údaje mohou být získány z šedotónového histogramu daného obrazu. Pro výpočet texturních charakteristik prvního řádu se používá:

**Střední úroveň šedi**  $\mu$  je dána vztahem:

$$\mu = \frac{1}{N} \sum_p i(p), \quad (2.1)$$

kde  $i(p)$  je úroveň šedi jednotlivého pixelu,  $p$  je počet úrovní šedi v obraze a  $N$  je počet pixelů v obraze.

**Rozptyl úrovní šedi**  $\sigma^2$  je dán podle vzorce:

$$\sigma^2 = \frac{1}{N} \sum_p \left( i(p) - \mu \right)^2. \quad (2.2)$$

**Zkreslení**  $S$  se vypočítá podle vzorce:

$$S = \frac{1}{N} \sum_p \frac{\left( i(p) - \mu \right)^3}{\sigma^3}. \quad (2.3)$$

**Kolísání kolem střední hodnoty**  $K$  je dáno vzorcem:

$$K = \frac{1}{N} \sum_p \frac{\left( i(p) - \mu \right)^4}{\sigma^4}. \quad (2.4)$$

Slabou stránkou statistik prvního řádu je, že neobsahují žádnou informaci o relativní pozici jednotlivých pixelů vůči okolí. To lze ukázat např. na níže zobrazených třech maticích, které mají všechny stejnou střední hodnotu  $\mu = 0,5$ , a přitom nejsou identické:

$$\begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \end{bmatrix}$$




## Statistiky druhého řádu

Ze statistik druhého řádu se zaměříme pouze na metodu matice současného výskytu, která bude následně použita k návrhu algoritmu pro detekci vrstvy nervových vláken.

**Matice současného výskytu (co-occurrence matrix):** Podle [3] je předpoklad, že použití šedotónových co-occurrence matic se stane jednou z nejpoužívanějších metod pro určení znaků charakteristických pro tuto texturu. Matice co-occurrence  $P_d$  o velikosti  $G \times G$  je pro zadaný vektor určující směr  $d = (dx, dy)$  je definována podle následujícího vzorce: Pro každý vstup  $(i, j)$  matice  $P_d$  je počet současného výskytu daného páru hodnot šedé  $i$  a  $j$ , jejichž vzdálenost je  $d$ , dána vzorcem [3]:

$$P_d = |\{(r, s), (t, v) : I(r, s) = i, I(t, v) = j\}|, \quad (2.5)$$

kde  $(r, s), (t, v) \in N \times N$ , a pozice  $(t, v) = (r + dx, s + dy)$ . Směr  $0^\circ$  je dán vektorem  $d = [0, 1]$ , směr  $45^\circ$  vektorem  $d = [-1, 1]$ , směr  $90^\circ$  vektorem  $d = [-1, 0]$  a směr  $135^\circ$  je dán vektorem  $d = [-1, -1]$ .



Obr. 2.1: Možné směry výpočtu matice co-occurrence

Pro lepší pochopení uvedeme příklad. Jedná se o obraz velikosti  $4 \times 4$  pixelů, který obsahuje 3 různé hodnoty šedé:

$$\begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 0 & 0 & 2 & 2 \\ 0 & 0 & 2 & 2 \end{bmatrix}$$

Matice co-occurrence tohoto obrazu bude mít velikost  $3 \times 3$ . Pro přesné určení jejích hodnot je ještě nutné zadat vektor  $d$ , který určuje, jak vzdálené hodnoty pixelů

budeme zkoumat. Nyní uvedeme různé výsledky matice co-occurrence pro různé vektory  $d$ .

$$\mathbf{P}_{1,0} = \begin{bmatrix} 4 & 0 & 2 \\ 2 & 2 & 0 \\ 0 & 0 & 2 \end{bmatrix}$$

$$\mathbf{P}_{0,1} = \begin{bmatrix} 4 & 2 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 2 \end{bmatrix}$$

$$\mathbf{P}_{1,1} = \begin{bmatrix} 3 & 1 & 1 \\ 1 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix}$$

Matice co-occurrence prozrazují některé vlastnosti o prostorové distribuci hodnot jasu v texturovaném obrazu. Např. pokud je většina vstupů v matici co-occurrence koncentrována po diagonále, pak se jedná o texturu drsnou, která respektuje zadaný vektor  $d$ . V [3] je možno z matice co-occurrence vyčíst až 14 příznaků. Nejpoužívanější jsou:

#### **Energie**

$$\sum_i \sum_j P_d^2(i, j). \quad (2.6)$$

#### **Entropie**

$$-\sum_i \sum_j P_d(i, j) \cdot \log P_d(i, j). \quad (2.7)$$

#### **Kontrast**

$$\sum_i \sum_j (i, j)^2 \cdot P_d(i, j). \quad (2.8)$$

#### **Homogenita**

$$\sum_i \sum_j \frac{P_d(i, j)}{1 + |i - j|}. \quad (2.9)$$

#### **Korelace**

$$\frac{\sum_i \sum_j (i - \mu_x)(j - \mu_y) P_d(i, j)}{\sigma_x \sigma_y}. \quad (2.10)$$

Správné nastavení parametrů pro co-occurrence matici je často poměrně obtížné. Neexistuje žádná metoda, která by umožnila určení vhodného vektoru  $d$ . Proto je nutné pro získání nejlepšího možného výsledku vyzkoušet více možností a podmínky pro zadaný problém vybrat manuálně.

### 2.1.2 Statistické testy

#### Test významnosti rozdílu mezi dvěma rozptyly – F-test

Podle [4] uvažujeme dva výběry s rozsahy  $n_1, n_2$  a s charakteristikami  $\bar{x}_1, s_1, \bar{x}_2, s_2$ , které byly odebrány ze dvou normálně rozložených základních souborů s parametry  $\mu_1, \sigma_1, \mu_2, \sigma_2$ . Testovacím kritériem je veličina

$$F = \frac{s_1^2 \frac{n_1}{n_1-1}}{s_2^2 \frac{n_2}{n_2-1}}, \quad (2.11)$$

které přísluší F rozložení  $n_1 - 1, n_2 - 1$  stupni volnosti. Pokud je  $F$  menší než kritická hodnota  $F_{\alpha/2}$ , nemáme důvod odmítnout předpoklad, že rozptyly se liší nepodstatně. Kritické hodnoty jsou tabelovány pro  $\alpha/2 = 0,025$  a  $0,005$ . Je třeba dbát na to, aby  $F \geq 1$ .

#### Test významnosti rozdílu dvou výběrových průměrů

##### a) Test významnosti rozdílu dvou výběrových průměrů, jestliže F-testem prokážeme, že $\sigma_1^2 = \sigma_2^2$

Jestliže F-testem prokážeme, že pro dané  $\alpha$  je  $\sigma_1^2 = \sigma_2^2$ , potom jako testovacího kritéria použijeme veličiny

$$t = \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{n_1 s_1^2 + n_2 s_2^2}} \sqrt{\frac{(n_1 + n_2 - 2)n_1 n_2}{n_1 + n_2}}, \quad (2.12)$$

které přísluší Studentovo rozložení s  $(n_1 + n_2 - 2)$  stupni volnosti. Pokud je  $t$  větší než kritická hodnota  $t(\alpha)$ , zamítáme nulovou hypotézu o rovnosti výběrových průměrů.

##### b) Test významnosti rozdílu dvou výběrových průměrů, jestliže F-testem prokážeme, že $\sigma_1^2 \neq \sigma_2^2$

Jestliže F-testem prokážeme, že pro dané  $\alpha$  je  $\sigma_1^2 \neq \sigma_2^2$ , potom jako testovacího kritéria použijeme veličiny

$$t = \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\frac{s_1^2}{n_1-1} + \frac{s_2^2}{n_2-1}}}, \quad (2.13)$$

jeho hodnotu srovnáváme s kritickou hodnotou  $t^*(\alpha)$ , kde

$$t^*(\alpha) = \frac{t_1(\alpha) \frac{s_1^2}{n_1-1} + t_2(\alpha) \frac{s_2^2}{n_2-1}}{\frac{s_1^2}{n_1-1} + \frac{s_2^2}{n_2-1}}, \quad (2.14)$$

kde  $t_1(\alpha)$  je kritická hodnota Studentova rozložení s  $(n_1 - 1)$  stupni volnosti a  $t_2(\alpha)$  je kritická hodnota Studentova rozložení s  $(n_2 - 1)$  stupni volnosti. Pokud je  $t$  větší jak kritická hodnota  $t^*(\alpha)$ , zamítáme nulovou hypotézu o rovnosti výběrových průměrů.

## 2.2 Analýza metodou matice co - occurrence

### 2.2.1 Návrh programu

V rámci projektu byl vytvořen funkční algoritmus pro výpočet matice co - occurrence a následně také některých jejích příznaků. Pro výpočet co - occurrence matice je možno ve vývojovém prostředí MATLAB použít příkaz `graycomatrix`. Pro lepší pochopení této problematiky však byla vytvořena funkce<sup>1</sup> *coocmat*, která umožňuje výpočet matice co - occurrence ve čtyřech směrech: 0°, 45°, 90° a 135°.

Dále program umožňuje vypočítat čtyři příznaky: entropii, energii, kontrast a homogenitu.

#### Vstupní parametry programu

Vytvořená funkce se v prostředí MATLAB spouští ve tvaru:

```
function[vyst_parametr] = coocmat(vst_obraz,vzdalenost,okno,dx,dy,smer,parametr)
```

Do výstupní proměnné funkce *vyst\_parametr* se ukládá určitý vypočtený příznak, který se určí pomocí proměnné *parametr*. Ve vektoru vstupních parametrů udává *vst\_obraz* celkový vstupní obraz, ze kterého se bude počítat jeden z příznaků, dále *vzdalenost* udává vzdálenost mezi porovnávanými pixely a *smer* reprezentuje volbu směru při výpočtu co - occurrence matice. Parametr *okno* udává velikost okna, které se bude pohybovat po vstupním obraze a ze kterého se bude počítat matice co - occurrence. Proměnné *dx*, *dy* umožňují posun okna o libovolnou vzdálenost ve vstupním obraze.

#### Vytvoření oblasti zájmu

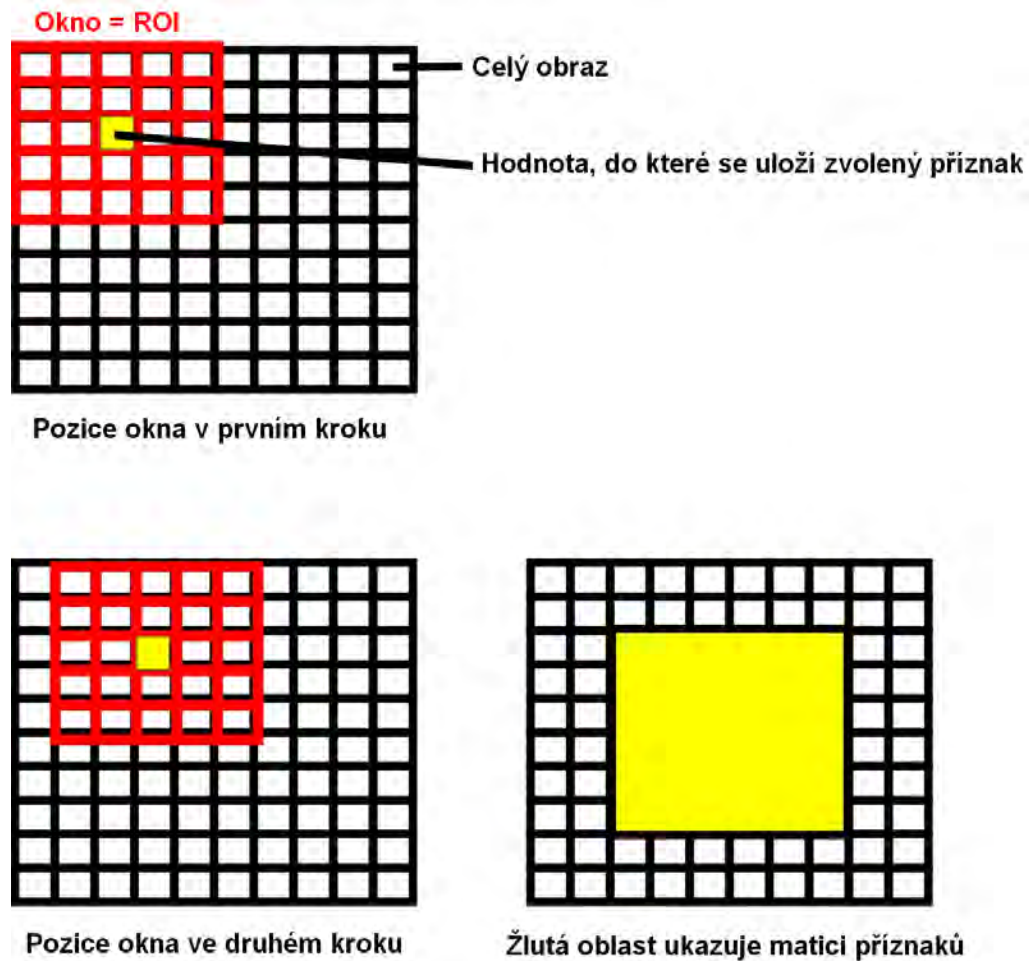
Vytvoření oblasti zájmu (ROI = Region Of Interest) ze vstupního obrazu, ze které budeme počítat matici co - occurrence, je realizováno následovně: Nejprve se vytvoří prázdná matice co - occurrence, která má velikost shodnou s počtem stupňů šedi v obraze. Pro naše obrazy bude mít tedy matice co - occurrence velikost  $256 \times 256$ . Poté se vytvoří dva cykly `for` pro posun okna po obraze. Proměnnou *dx* a *dy* lze eventuálně změnit krok, po kterém se bude okno posunovat. V každém kroku nového výpočtu matice co - occurrence se nejprve matice nuluje.

---

<sup>1</sup>všechny funkce související s analýza metodou matice co - occurrence jsou uloženy na přiloženém CD v adresáři: `./program/cooc/`

```

cooc = zeros(velikost_matice, velikost_matice);
for radek = 1 : dx : velikost_vst_obrazu_x
    for sloupec = 1 : dy : velikost_vst_obrazu_y
        ROI = vst_obraz(radek:radek+(okno-1), sloupec:sloupec+(okno-1));
        cooc(1:end, 1:end) = 0;
    
```



Obr. 2.2: Popis posunu okna po obraze

### Výpočet matice co - occurrence pro různé směry

Výběr směru, pro výpočet matice co - occurrence je realizován příkazem **switch**. Na začátku běhu programu se vytvoří prázdná co - occurrence matice, na konci každého kroku je nulována. Co - occurrence matice bude mít pro námi používané obrazy vždy velikost  $256 \times 256$ , protože používáme obrazy s 256 stupni šedi.

Výpis části programu, který vypočítává matici co-occurrence pro směr 0°:

```
for radek_masky = 1 : size(ROI,1)
    for sloupec_masky = 1 : size(ROI,2) - vzdalenost
        radek_cooc = ROI(radek_masky,sloupec_masky);
        sloupec_cooc = ROI(radek_masky,sloupec_masky + vzdalenost);
        cooc_0(radek_cooc,sloupec_cooc) = cooc_0(radek_cooc,sloupec_cooc) + 1;
    end
end
```

Výpis části programu, který vypočítává matici co-occurrence pro směr 45°:

```
for radek_masky = 1 + vzdalenost : size(ROI,1)
    for sloupec_masky = 1 : size(ROI,2) - vzdalenost
        radek_cooc = ROI(radek_masky,sloupec_masky);
        sloupec_cooc = ROI(radek_masky - vzdalenost,sloupec_masky + vzdalenost);
        cooc_45(radek_cooc,sloupec_cooc) = cooc_45(radek_cooc,sloupec_cooc) + 1;
    end
end
```

Výpis části programu, který vypočítává matici co-occurrence pro směr 90°:

```
for radek_masky = 1 + vzdalenost : size(ROI,1)
    for sloupec_masky = 1 : size(ROI,2)
        radek_cooc = ROI(radek_masky,sloupec_masky);
        sloupec_cooc = ROI(radek_masky - vzdalenost,sloupec_masky);
        cooc_90(radek_cooc,sloupec_cooc) = cooc_90(radek_cooc,sloupec_cooc) + 1;
    end
end
```

Výpis části programu, který vypočítává matici co-occurrence pro směr 135°:

```
for radek_masky = 1 + vzdalenost : size(ROI,1)
    for sloupec_masky = 1 + vzdalenost : size(ROI,2)
        radek_cooc = ROI(radek_masky,sloupec_masky);
        sloupec_cooc = ROI(radek_masky - vzdalenost,sloupec_masky - vzdalenost);
        cooc_135(radek_cooc,sloupec_cooc) = cooc_135(radek_cooc,sloupec_cooc) + 1;
    end
end
```

## Výpočet příznaků z co - occurrence matice

Navržený program dokáže z matice co - occurrence vypočítat čtyři příznaky: entropii, energii, kontrast a homogenitu. Pro výpočet každého příznaku byla vytvořena funkce, kde jako vstupní proměnná vstupuje matice co - occurrence a výstupem je pak hodnota daného příznaku. Tato hodnota se následně umístí do výsledné matice. Výsledná matice bude tedy mít rozměry vstupního obrazu zmenšené při okrajích o polovinu velikosti okna. Toto okno se poté posune na další pozici. Realizace výpočtu, který se bude u matice co - occurrence počítat, je dána příkazem **switch**.

**Funkce pro výpočet entropie:** Entropie se vypočítá podle vzorce 2.7. Pro výpočet entropie byla vytvořena funkce, kde výstupní hodnotou je hodnota entropie, která se spočítá z matice co - occurrence a dalším vstupním parametrem funkce je `hodnota_sedi_a_log2_sedi`, což je předem vytvořený vektor hodnot  $P \cdot \log_2 P$  šedi v možném intervalu 0 až 255.

```
function [Entropie] = entropy(cooc,hodnota_sedi_a_log2_sedi)
entr_v_cooc = hodnota_sedi_a_log2_sedi(cooc + 1);
Entropie = -1 * sum (entr_v_cooc(:));
```

**Funkce pro výpočet energie:** Pro výpočet energie byl použit vztah 2.6, podle kterého byla vytvořena funkce:

```
function [Energie] = energy(cooc)
energie_v_cooc = (cooc).^2;
Energie = sum(energie_v_cooc (:));
```

**Funkce pro výpočet kontrastu:** Pro výpočet kontrastu byl použit vztah 2.8, podle kterého byla vytvořena funkce:

```
function [kontrast] = contrast(cooc)
[sloupce,radky,hodnota] = find(cooc ~= 0);
for s=1:size(sloupce, 1)
    kontrast_v_cooc(s) = (sloupce(s) - radky(s)).^2*cooc(sloupce(s), radky(s));
end
kontrast = sum( kontrast_v_cooc);
```

**Funkce pro výpočet homogenity:** Pro výpočet homogenity byl použit vztah 2.9, podle kterého byla vytvořena funkce:

```
function [homogenita] = homogen(cooc)
[slopce,radky,hodnota] = find(cooc~=0);
for s=1:size(slopce, 1)
    hom_v_cooc(s) = cooc(slopce(s), radky(s))/(1+abs(slopce(s) - radky(s)));
end
homogenita = sum(hom_v_cooc);
```

### Umístnění příznaku do matice příznaků

Po výpočtu zvoleného příznaku příslušnou funkcí se příznak umístí do výsledné matice příznaků. Příznak se uloží do středu zvoleného okna. Z toho plyne, že výsledná matice příznaků bude oproti vstupnímu obrazu zmenšena u okrajů o velikost poloviny okna, viz obr. 2.2.

```
matice_priznaku(radek + round(okno / 2), sloupec + round(okno / 2)) = priznak;
```


### 2.2.2 Výběr testovacích textur

Pro výběr testovacích textur byly použity RAW obrazy oka nemocného pacienta s lokálním výpadkem nervových vláken, aby bylo možno porovnat tyto oblasti s oblastmi se zdravými nervovými vlákny. Těchto snímků bylo k dispozici velmi málo. Vyhovaly pouze dva snímky, ze kterých bylo dohromady vybráno 10 výřezů: 5 výřezů, které obsahovaly nervová vlákna a 5 výřezů s výpadkem nervových vláken. Každý výřez má velikost  $64 \times 64$  pixelů. Tato velikost byla shledána jako maximální možná velikost, ve níž se dají nalézt oblasti bez cév, které by jinak narušily texturu a ovlivnily pozdější výpočet hodnot.


Na obr. 2.3 je zobrazeno levé oko pacienta s vyznačenými oblastmi výpadku nervových vláken. Tyto oblasti vyznačil oftalmolog. Pro základ obr. 2.4 posloužil stejný barevný RAW obraz. Na šedotónový byl převeden tak, že byla vypuštěna červená R složka a složky G a B byly sloučeny do šedotónového obrazu. Poté byl zvýrazněn kontrast pomocí adaptivního histogramu. Z tohoto obrazu bylo vybráno celkem šest výřezů. Z toho tři výřezy byly vybrány v oblastech, které obsahují zdravá nervová vlákna (zelené čtverečky 1, 2 a 3), a tři výřezy obsahující výpadek (červené čtverečky 6, 7 a 8). Na obr. 2.5 je druhý snímek. Jedná se o pravé oko pacienta s vyznačením oblastí výpadku nervových vláken. Na obr. 2.6 je upravený stejný




snímek. Postup převedení na šedotónový obraz je obdobný jako u obr. 2.4. Z tohoto obrazu byly vybrány celkem čtyři výřezy. Výřezy posloužily pro následnou texturní analýzu pomocí co - occurrence matic.




Obr. 2.3: Levé oko: Výchozí obraz se zobrazením výpadku nervových vláken



Obr. 2.4: Levé oko: upravený obraz s vyznačenými výřezy



Obr. 2.5: Pravé oko: Výchozí obraz se zobrazením výpadku nervových vláken



Obr. 2.6: Pravé oko: upravený obraz s vyznačenými výřezy

### 2.2.3 Analýza testovacích textur


Pomocí příkazu `improfile` jsme vytvořili „profily řezů“ jednotlivými texturami. Tyto profily znázorňují hodnoty stupňů šedi podél řezů. Byla vynaložena snaha o nalezení jisté podobnosti v periodicitě jasových hodnot u výřezů obsahujících zdravou tkáň (výřezy s názvem *zdravé01-05*). Tato periodicitu je způsobená výskytem nervových vláken, a měla by být vodítkem k volbě vhodné vzdálenosti pixelů při výpočtu co-occurrence matice. Řezy byly vedeny kolmo na směr nervových vláken, viz. obr. 2.7, obr. 2.8 a obr. 2.9.

Jak je z grafů patrné, určitá opakování v intenzitě jasu se vyskytují, avšak ne se stejnou periodou. Lze říci, že opakování v hodnotách šedi se vyskytují ve vzdálenostech od 3 do 12 pixelů. Intenzita šedi kolísá zhruba s výchylkou 20 až 60.

Navíc, jak je patrné z obrázků 2.9, obr. 2.10 a obr. 2.11, se podobná opakování vyskytují i u textur s výpadkem nervových vláken.




Obr. 2.7: Profil intenzity texturami s názvem *zdravé01* a *zdravé02*




Obr. 2.8: Profil intenzity texturami s názvem *zdravé03* a *zdravé04*



Obr. 2.9: Profil intenzity texturami s názvem *zdravé05* a *výpadek06*



Obr. 2.10: Profil intenzity texturami s názvem *výpadek07* a *výpadek08*




Obr. 2.11: Profil intenzity texturami s názvem *výpadek09* a *výpadek10*

## 2.2.4 Srovnání matic co-occurrence a jejich jednotlivých příznaků

### Srovnání matic co-occurrence zdravých tkání s tkáněmi s výpadkem

Porovnáním matic co-occurrence testovacích textur pro jednotlivé směry výpočtu bylo konstatováno, že nejsme schopni na základě tohoto porovnání rozhodnout, zda se jedná o texturu obsahující nervová vlákna či texturu obsahující výpadek. Na obr. 2.12 je ukázka co-occurrence matice testovací textury zdravé tkáně pro různé směry výpočtu. Matice co-occurrence obsahující textury s výpadkem nervových vláken se jeví jako prakticky totožná a nebyla nalezena žádná vizuální ani statistická odlišnost.




Obr. 2.12: Matice co-occurrence pro texturu s názvem *zdravé02* pro různé směry

## Srovnání jednotlivých příznaků matic co - occurrence

Naším cílem bylo nalezení určitého příznaku, kterým by se lišily textury obsahující nervová vlákna od textur s výpadkem ve vrstvě nervových vláken. Tím by se nám podařilo ze vstupního obrazu vysegmentovat oblasti s nervovými vlákny od oblastí s výpadkem.

Jak již bylo řečeno, pro výpočet energie z matic co-occurrence byl použit vzorec 2.6, pro entropii vzorec 2.7, pro kontrast 2.8 a pro homogenitu 2.9.

Dále bylo nutno zvolit vhodnou velikost okna. Na obr. 2.13 je zobrazena matice příznaků energie při vzdálenosti porovnávaných pixelů = 1, směru výpočtu matice co - occurrence =  $0^\circ$  a při různých velikostech okna. Jak je z obrázku patrné, okna o velikosti 5 a 10 jsou pro tuto texturu zvolena nevhodně, protože informace v nich obsažená není spojitá a těžko bychom na jejich základě danou texturu posuzovali. Lépe se z hlediska spojitosti jeví výsledky s oknem o velikosti 20 a 30. Pro následující analýzu bylo zvoleno okno o velikosti 30, které se jeví jako optimální u všech příznaků.



Obr. 2.13: Obrazy matic příznaků energie pro různé velikosti okna

### 2.2.5 Hodnocení funkčnosti metody

Bylo vypočteno velké množství příznaků matic co - occurrence s různým nastavením vstupních parametrů a z nich vykresleny obrazy. Bylo zkoumáno, zda se při určitém nastavení bude tento obraz lišit u textur obsahujících nervová vlákna od textur obsahujících výpadek. To se však i přes značnou snahu nepodařilo.

Tabulka A.1 umístěná v příloze na str. 74 ukazuje hodnoty průměrných energií jednotlivých testovacích textur vypočtených z matic co - occurrence pro jednotlivé směry a různé vzdálenosti porovnávaných pixelů. Protože se u textur nepodařilo nalézt žádnou harmonickou periodicitu, byly zvoleny vzdálenosti porovnávaných pixelů 1 až 15. Podobná tabulka A.2 pro průměrné hodnoty středních entropií a kontrastů byla vytvořena na str. 75. Pro omezený rozsah této publikace již nebyly vypsány všechny textury, ale jen některé, u kterých je patrné, že se výsledné hodnoty u textur obsahující nervová vlákna a výpadek překrývají. Tabulka s homogenitou také nepřinesla očekávaný výsledek a pro povolený vymezený rozsah této práce byla vypuštěna. Jak je z tabulek patrné, není možno na základě žádného testovaného příznaku rozlišit texturu obsahující nervová vlákna od textury obsahující výpadek nervových vláken. Můžeme tedy konstatovat, že analýza metodou matice co - occurrence není k řešení našeho problému vhodná.



## 2.3 Spektrální analýza

Z důvodu negativního výsledku při detekci výpadku nervových vláken metodou sdružených histogramů pomocí matic co-occurrence jsme se pokusili nalézt jinou metodu. Rozhodli jsme se pro „směrovou spektrální analýzu“. Základní myšlenkou směrové spektrální analýzy je, že nervová vlákna mají určitý směr a tato směrovost by měla být patrná v jejich spektru.

### 2.3.1 Teoretický úvod

Spektrum vstupního obrazu získáme pomocí dvourozměrné Fourierovy transformace vstupního obrazu [1]:

$$F_{u,v} = \mathbb{FT} |f(x, y)| = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \cdot e^{-j(ux+vy)} dx dy. \quad (2.15)$$

Zpětná dvourozměrná Fourierova transformace je definovaná vztahem [1]:

$$f_{x,y} = \mathbb{FT}^{-1} |F(u, v)| = \frac{1}{4\pi^2} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \cdot e^{j(ux+vy)} du dv. \quad (2.16)$$

Dvourozměrná diskretní Fourierova transformace (2D DFT), je definována podle vztahu [1]:

$$F_{m,n} = \frac{1}{N} \sum_{i=0}^{N-1} \sum_{k=0}^{N-1} f_{i,k} \cdot e^{-j\frac{2\pi}{N}(mi,nk)}. \quad (2.17)$$

Zpětná 2D DFT, je definovaná vztahem [1]:

$$f_{i,k} = \frac{1}{N} \sum_{m=0}^{N-1} \sum_{n=0}^{N-1} F_{m,n} \cdot e^{-j\frac{2\pi}{N}(mi,nk)}. \quad (2.18)$$

### 2.3.2 Výběr oblastí zájmu pro spektrální analýzu

RAW snímků jsme měli k dispozici jen omezené množství a navíc tyto snímky mají nižší rozlišení než *jpg* snímky. Proto bylo rozhodnuto, že pro další práci budeme používat snímky *jpg* s nejnižší možnou kompresí. Celobarevných snímků s nízkou kompresí a obsahujících výpadek jsme měli k dispozici jen velmi málo, proto pro následující testování byly zvoleny jen snímky snímané přes filtr BPB45. Bylo vybráno 6 snímků očí nemocných pacientů s lokálním výpadkem ve vrstvě nervových vláken a 11 snímků očí zdravých pacientů. Ze snímků nemocných pacientů bylo manuálně vybráno 30 oblastí, které obsahovaly výpadek ve vrstvě nervových vláken (skupina A) a 30 oblastí se zdravou tkání (skupina B). Ze snímků zdravých pacientů bylo zvoleno rovněž 30 oblastí se zdravou tkání (skupina C). Výřezy mají velikost  $129 \times 129$  pixelů. Tím, že *jpg* snímky mají 4 krát vyšší rozlišení než RAW snímky, zabírají takto velké výřezy ve snímku stejnou plochu jako výřezy  $64 \times 64$  pixelů u RAW dat.




### 2.3.3 Návrh programu pro metodu směrové spektrální analýzy

Pro výpočet 2D DFT byl použit příkaz `fft2`. Protože tento příkaz vkládá nulovou frekvenci 2D spektra do levého horního rohu, byl následně použit příkaz `fftshift`, který nulovou frekvenci vloží do středu 2D spektra. Pokud vezmeme absolutní hodnoty ze spekter, dostaneme spektra amplitudová.

Výpis části programu, který vypočítá amplitudová spektra:

```
vstupni_obraz = imread('obraz.tiff');  
spektrum = fft2(vstupni_obraz);  
amplitudove_spektrum = fftshift(log10(abs(spektrum)));
```

Na obr. 2.14 jsou vykreslena amplitudová spektra pro naše testovací textury:



Obr. 2.14: Horní řada obsahuje spektra textur obsahujících výpadek ve vrstvě nervových vláken, ve spodní řadě jsou spektra textur obsahující nervová vlákna. Zde je patrnější směrovost spektra.

U 2D spekter obsahující nervová vlákna (viz obr. 2.14 – spodní řada) je patrná jistá směrovost spektra. Tato směrovost by mohla být způsobena právě výskytem nervových vláken, protože ve 2D spektrech s výpadkem nervových vláken se vyskytuje v menší míře (viz obr. 2.14 – horní řada).

## Návrh části programu pro tvorbu výsečí spektra

Pro kvantitativní určení směrovosti 2D spektra rozdělíme toto spektrum na několik výsečí. Protože 2D spektrum je symetrické, stačí analyzovat jeho horní polovinu. V programu je rozdělení na výseče realizováno následovně<sup>2</sup>: Nejprve se vytvoří tři hraniční body potřebné pro tvorbu každé výseče. První hraniční bod je ve středu 2D spektra, zbylé 2 body je nutno vypočítat. Pro každou výseč se vytvoří maska, která bude obsahovat ve výseči hodnoty 1, mimo výseč hodnoty 0. Poté se každá maska pronásobí s 2D spektrem a tím vzniknou požadované výseče 2D spektra. Z každé výseče se vypočítá její průměrná energie.

Funkce pro vytvoření výsečí má pět vstupních proměnných: *R\_sp* určuje rozměr 2D spektra. 2D spektrum bude mít rozměr  $x \times x$ , kde  $x = 2 \cdot R_{sp} + 1$ . Proměnná *n* ovlivňuje šířku výseče a její úhel se vypočítá  $180/n$ . Proměnné *stred\_x* a *stred\_y* určují souřadnice středu 2D spektra. Proměnná *krok* udává počet stupňů, o kolik výseč v každém kroku rotuje. Proměnné *od* a *do* určují poloměry hraničních kružnic pro mezikružší (viz obr. 2.16). Význam tohoto mezikružší bude vysvětlen později. Další proměnnou je *anglout*, která převádí stupně na radiány. Do proměnné *pocet\_kroku* se vypočítá celkový počet otočení výseče k pokrytí horní poloviny spektra, tedy k pokrytí  $180^\circ$ . Popsaná část programu je navržena následovně:

```
function [pole_masek,pocet_kroku] = spektralni_analyza_vysece(R_sp,n,krok,od,do)
stred_x=R_sp+1;
stred_y=stred_x;
uhel=180/n;
anglout = deg2rad(uhel);
pocet_kroku = (180/krok) - (uhel/krok) + 1;
```

Ve funkci je vytvořen cyklus `for`, který počítá hraniční body jednotlivých výsečí. V každém cyklu vypočítá hraniční body pro jednu výseč, proto je počet cyklů roven celkovému počtu vytvořených výsečí. Proměnná s názvem *otoceni* je v každém cyklu zvětšována o předdefinovaný počet stupňů, tedy o proměnnou *krok*. Proměnná *uhel1* je aktuální úhel natočení zvětšený o úhel výseče definovaný proměnnou *uhel*. Pod tímto úhlem bude od středu 2D spektra ležet první hraniční bod. Jeho souřadnice se uloží do proměnných *X1* a *Y1*. Protože se však hraniční bod neurčuje od počátku souřadnic, ale od středu 2D spektra, jsou souřadnice zvětšeny o hodnotu `textitR_sp+1`. Konečná poloha hraničních bodů se postupně ukládá do pole buněk *c1* pro sloupce a *r1* pro řádky. To samé se v každém cyklu děje dvakrát, vždy pro výpočet dvou hraničních bodů.

<sup>2</sup>Funkce pro výpočet výsečí je na příloženém CD: `./program/spektralni_analyza_vysece.m` a celá funkce pro metodu směrové analýzy na: `./program/spektralni_analyza_pro_celkovou.m`

Cyklus popsaný na předchozí straně je v programu realizován následovně:

```
for a = 0:pocet_kroku
    otoceni = krok*a;
    uhel1 = deg2rad(uhel+otoceni);

    [X1,Y1] = pol2cart(uhel1,64);
    XX1 = X1+R+1;
    YY1 = Y1+R+1;
    c1{1,a+1} = round(XX1);
    r1{1,a+1} = round(YY1) ;

    [X2,Y2] = pol2cart(uhel1-anglout,64);
    XX2 = X2+R+1;
    YY2 = Y2+R+1;
    c2{1,a+1} = round(XX2);
    r2{1,a+1} = round(YY2);
end
```

Na následujícím obr. 2.15 je ukázka rotace výseče:



Obr. 2.15: Ukázka postupné rotace výseče. Vyobrazeny první 4 kroky z celkových 22 kroků.


V další části programu je cyklus, který by měl zaručit, že budou ze spektra vybrány jen ty složky, ve kterých by potenciálně mohla být obsažena nervová vlákna. Ze spektra je potřeba odstranit vysokofrekvenční šum při okraji spektra a také nízkofrekvenční hodnoty blízké středu 2D spektra. K tomuto účelu byl navržen následující cyklus, ve kterém jsou vytvořeny dvě soustředné kružnice s různými poloměry a se středy totožnými se středem 2D spektra. Oblast mezi těmito kružnicemi je pak naše hledaná oblast. Proměnné *od* a *do* určují poloměry těchto kružnic a jsou vyjádřeny jako poměry poloměrů kružnic k proměnné *R<sub>sp</sub>*. Program je realizován tak, že se spočte vzdálenost každého bodu od středu spektra. Pokud je tato vzdálenost v rozmezí zvolených poloměrů, je tomuto bodu do matice *eps* přiřazena jednička.

Realizace v programu je následující:

```
delka_strany = R_sp*2+1;
eps(1:delka_strany,1:delka_strany) = 0;
init_x = stred_x-R_sp;
init_y = init_x;

for i = 1:(2*R_sp+1)
    for j = 1:(2*R_sp+1)
        dist = ((init_x+i)-stred_x)^2+((init_y+j)-stred_y)^2;
        dist = sqrt(dist);
        dist = ceil(dist);
        if dist < (R_sp/do) && dist > (R_sp/od)
            eps(init_x+i, init_y+j) = 1;
        end
    end
end
```

Výsledek výsledného mezikruží uložené do matice *eps* pro  $od = 1/16$  a  $do = 1/3$  je znázorněn na obr. 2.16



Obr. 2.16: Mezikruží pro výběr relevantních hodnot ze spektra

V následující části programu se nejprve z hraničních bodů vytvoří jednotlivé výseče. K tomu slouží příkaz *roipoly*, který z hraničních bodů vytváří mnohoúhelník (v našem konkrétním případě trojúhelník). Bodům ležícím uvnitř tohoto mnohoúhelníku je přiřazena jednička, bodům ležícím mimo nula. Tím jsou vytvořeny výseče. Průnikem jednotlivých výsečí s mezikružím *esp* se do proměnné *BW* uloží konečná podoba masky, tedy výseč jen v požadované vzdálenosti od středu. Do proměnné *pole\_masek* se postupně uloží všechny masky. Programová realizace je uvedena na následující straně.

```

pomocna = zeros(delka_strany,delka_strany);
pole_masek = zeros(delka_strany,delka_strany,pocet_kroku);

for e = 1:pocet_kroku
    c=[stred_x c1{1,e} c2{1,e} stred_x];
    r=[stred_x r1{1,e} r2{1,e} stred_x];
    BWW = roipoly(pomocna,c,r);
    BWW = double(BWW);
    BW = BWW.*eps;
    BW(:,stred_x)=0;
    pole_masek(:,:,e)=BW;
end

```

V následující části programu je v prvním cyklu `for` vytvořena proměnná *pocet*. Tato proměnná počítá, kolik pixelů obsahují jednotlivé masky. Tento údaj je potřebný k výpočtu průměrné energie. V druhém cyklu `for` vznikají roznásobením masek s 2D spektrem hledané výseče 2D spekter. Poté se podle vzorce 2.6 do proměnné *celkova\_energie* vypočítá celková energie ve výseči. Protože však jednotlivé výseče nemají stejný počet pixelů, bylo by porovnání celkové energie výsečí zavádějící. Proto se určí průměrná energie výsečí. Nakonec se do proměnné *rozdil\_energii* uloží rozdíl mezi maximální a minimální průměrnou energií jednotlivých výsečí. Toto já náš hledaný parametr ve spektru. Realizace je následující:

```

for e = 1:pocet_kroku
    k=0;
    for o = 1:2*R
        for p = 1:2*R
            if pole_masek(o,p,e) == 1
                k =k+1;
            end
        end
    end
    pocet(e) = k;
end

for e = 1:pocet_kroku
    pole_spekter(:,:,e) = pole_masek(:,:,e).*amplitudove_spektrum;
    energie(:,:,e) = pole_spekter(:,:,e).^2;
    celkova_energie = sum(sum(energie(:,:,e)));
    prumerna_energie(e) = celkova_energie/pocet(e);
    rozdil_energii = max(prumerna_energie(:)) - min(prumerna_energie(:));
end

```

### 2.3.4 Porovnání výsledků

Byly zkoušeny různé nastavení uhlí výšečí v kombinaci s různými hodnotami nastavení mezikruží. Jako neoptimálnější se ukázal úhel výšeče  $22,5^\circ$  a mezikruží při hodnotách  $od = \frac{1}{16}$  a  $do = \frac{1}{3}$ . Při tomto nastavení byly programem analyzovány testovací texture získané v kap. 2.3.2. Výsledky jsou uvedeny v příloze v tab. A.3, A.4 a A.5. V tab. 2.1 jsou uvedeny průměrné hodnoty maximálních energií z těchto tabulek.

Tab. 2.1: Maximální rozdíly energií u  $15^\circ$  výšečí 2D spekter testovacích textur

Maximální rozdíly energií	max $\Delta E$ : sk. A	max $\Delta E$ : sk. B	max $\Delta E$ : sk. C
<b>B složka</b>	$1,070 \pm 0,222$	$1,702 \pm 0,330$	$2,087 \pm 0,499$
<b>G složka</b>	$1,099 \pm 0,255$	$1,849 \pm 0,391$	$2,224 \pm 0,529$
<b>B složka, adapthisteq</b>	$1,263 \pm 0,287$	$2,060 \pm 0,411$	$2,545 \pm 0,653$
<b>G složka, adapthisteq</b>	$1,301 \pm 0,303$	$2,200 \pm 0,483$	$2,720 \pm 0,666$

Z těchto hodnot byl podle postupu uvedeného v kap. 2.1.2 proveden t-test. Jako nulovou hypotézu  $H_0$  zvolíme: „Neexistuje žádný rozdíl v průměrných hodnotách sledovaného parametru mezi skupinami A a B (respektive A a C)“. Platnost této hypotézy budeme sledovat na hladině významnosti  $p = 0.01$ . Tabulka 2.2 uvádí výsledky t-testu. Hodnoty 1 znamenají, že hypotézu  $H_0$  zamítáme.

Tab. 2.2: Výsledky t-testu pro jednotlivé typy testu.

	B složka	G složka	B složka, hist.	G složka, hist.
<b>B – A</b>	1	1	1	1
<b>C – A</b>	1	1	1	1
<b>B – C</b>	1	1	1	1

Jak je z tabulky 2.2 patrné, ve všech testovaných případech jsou rozdíly výběrových průměrů statisticky významné. Existují tedy statisticky významné rozdíly mezi tkání obsahující výpadek ve vrstvě nervových vláken a tkání obsahující nervová vlákna u nemocného oka (B – A) a zdravého oka (C – A), ale dokonce i mezi tkání obsahující nervová vlákna u nemocného a zdravého oka (B – C).

### 2.3.5 Hodnocení funkčnosti metody

Díky tomuto výsledku můžeme konstatovat, že metoda směrové spektrální analýzy by mohla být vhodná pro kvantitativní hodnocení oblastí vrstvy nervových vláken.

## 2.4 Metoda vycházející z hranové reprezentace

### 2.4.1 Teoretický úvod

Metoda vychází z myšlenky, že oblasti s nervovými vlákny obsahují větší rozptyl jasů, a tím také zřetelnější hrany než oblasti s výpadkem nervových vláken. Tento poznatek vybízí k použití hranového detektoru. Jako vhodný se ukázal hranový detektor na bázi Laplacian of Gaussian (LoG). Tento hranový detektor pracuje tak, že se nejprve vytvoří maska filtru podle vzorců 2.19 a 2.20, [5] :

$$h_g(n_1, n_2) = e^{-(n_1^2 + n_2^2)/2\sigma^2} \quad (2.19)$$

$$h(n_1, n_2) = \frac{(n_1^2 + n_2^2 - 2\sigma^2)h_g(n_1, n_2)}{2\pi\sigma^6 \sum_{n_1} \sum_{n_2} h_g} \quad (2.20)$$

Po filtraci vstupního obrazu touto maskou se hledají hrany podle průchodu nulou. Pokud je mezi sousedními pixely filtrovaného obrazu zaznamenán průchod nulou a rozdíl těchto dvou pixelů je větší než práh, je tento pixel označen jako hrana, tzn. do binární hranové reprezentace je uložena jednička. Vstupním obrazem je šedotónový obraz, výstupem je tedy obraz binární o stejných rozměrech jako obraz vstupní. Prah je možno určit empiricky nebo vypočítat automaticky podle vztahu:

$$thresh = \frac{3}{4} \left[ \frac{1}{n_1 n_2} \sum_{n_1} \sum_{n_2} abs(i) \right], \quad (2.21)$$

kde  $i$  jsou jednotlivé prvky matice obrazu filtrovaného maskou filtru LoG na souřadnicích  $n_1$  a  $n_2$ .

### 2.4.2 Návrh programu

Tato metoda je ve vývojovém prostředí MATLAB realizována pomocí funkce `edge` a má podobu:


```
BW = edge(I, 'log', thresh, sigma);  
bwAreaOpenBW = bwareaopen(BW, 10);
```

Proměnná  $I$  je vstupní obraz,  $BW$  je výstupní binární hranovou reprezentací po aplikaci hranového detektoru. Výraz `'log'` značí, že se jedná o LoG hranový detektor. Dále  $\sigma$  určuje rozměry a hodnoty LoG filtru. Tento filtr bude mít rozměry  $n \times n$ , kde  $n$  se vypočítá podle vzorce 2.22. Proměnná  $n$  se zaokrouhluje na celá čísla

směrem nahoru. Proměnná *thresh* je práh a vypočte se podle vzorce 2.21. Funkce *bwareaopen* odstraní hrany kratší než je předdefinovaný počet pixelů.

$$n = (\textit{sigma} \cdot 3) \cdot 2 + 1. \quad (2.22)$$

Na obr. 2.17 je naznačeno možné fungování metody. Výřez na obr. 2.17a) obsahuje v horní levé části oblast s nervovými vlákny, spodní pravá část obsahuje výpadek. Výsledek po aplikaci LoG operátoru je na obr. 2.17b). Práh je počítán automaticky, *sigma* je předdefinována na hodnotu 2. Maska LoG operátoru má při tomto nastavení velikost  $13 \times 13$ . Jak je patrné z tohoto obrázku, detekované hrany jsou častěji zastoupeny a mají větší délku v oblastech se zdravou tkání. Z tohoto důvodu je dalším krokem vymazání krátkých hran – v našem případě kratších než 10 pixelů (viz. obr. 2.17c)). Nakonec je vytvořen tříbarevný obraz (2.17d): černá pro oblast, která ve svém okolí  $128 \times 128$  pixelů obsahuje méně než 900 hranových pixelů z obr. 2.17c), šedá pro oblast 900 – 1000 pixelů a bílá nad 1000 pixelů.



Obr. 2.17: Ukázka fungování metody vycházející z hranové reprezentace: a) výřez snímku, b) hrubá hranová reprezentace, c) upravená hranová reprezentace, d) klasifikovaný snímek (černá – tkáň obsahující výpadek ve vrstvě nervových vláken)



### 2.4.3 Porovnání výsledků

#### Statistika celé oblasti zájmu

Při statistice celé oblasti zájmu bylo provedeno srovnání prostorové hustoty detekovaných hran u snímků zdravých pacientů se snímky pacientů s oblastí s výpadkem ve vrstvě nervových vláken. Analýza proběhla v oblasti zájmu určené podle kap. 3.1.2. Z této oblasti byly ještě vyňaty oblasti obsahující cévy podle postupu popsaného v kap. 3.1.1. Je zřejmé, že ponecháním cév v oblasti zájmu by byla následná detekce hran ovlivněna.

Tyto oblasti zájmu byly postupně analyzovány pomocí dvou různě nastavených hodnot prahu. Práh byl nejprve nastaven automaticky podle vzorce 2.21 a poté pevně na hodnotu 0,0007.

U snímků zdravých pacientů byla hodnocena prostorová hustota na celé ploše oblasti zájmu. U snímků s výpadkem byla oblast zájmu manuálně rozdělena na oblast se zdravou tkání a na oblast obsahující výpadek ve vrstvě nervových vláken. Z tab. 2.3 a 2.4 je patrné, že v oblastech s výpadkem ve vrstvě nervových vláken je prostorová hustota detekovaných hran nižší.

Tab. 2.3: Procentuální zastoupení detekovaných hran u snímku obsahující výpadek ve vrstvě nervových vláken

Název souboru	1B	4B	7B
Zdravá tkáň, práh automaticky, [%]	8,2463	6,8907	6,3448
Výpadek, práh automaticky, [%]	5,2327	4,1975	4,5193
Zdravá tkáň, práh 0,0007, [%]	4,0774	3,9069	3,4495
Výpadek, práh 0,0007, [%]	1,8007	1,8606	2,0908

Tab. 2.4: Procentuální zastoupení detekovaných hran u snímku zdravého oka

Název souboru	8	9	10	11
Zdravá tkáň, práh automaticky, [%]	7,3985	7,9681	8,2104	6,7773
Zdravá tkáň, práh 0,0007, [%]	9,7005	9,1319	6,1726	6,3904
Název souboru	12	14	17	
Zdravá tkáň, práh automaticky, [%]	8,1093	8,6449	7,559	
Zdravá tkáň, práh 0,0007, [%]	5,5546	4,2369	7,2665	

Je však nutno podotknout, že výsledky jsou poněkud ovlivněny segmentací cév. K analýze byly použity snímky snímané přes zelený filtr. Z nich byla vzata GB složka podle vzorce 1.1. Jak již bylo řečeno dříve, u těchto snímků jsou nervová vlákna výrazná. To má za následek, že některé oblasti s výraznými nervovými vlákny

jsou mylně detekovány jako céva, proto nejsou do statistiky zahrnuty. Tím je zřejmě procento detekovaných hran u zdravé tkáně sníženo.

### Statistika ve vybraných oblastech

Při tomto porovnání se také srovnávala prostorová hustota detekovaných hran. Jako vstupní data byly použity výřezy z kap. 2.3.2. Práh byl zvolen automaticky. V příloze v tabulkách A.6, A.7 a A.8 jsou zaznamenány počty detekovaných pixelů jako hrana u jednotlivých testovacích textur. V tab. 2.5 jsou zaznamenány průměrné hodnoty z těchto měření.

Tab. 2.5: Výsledná prostorová hustota detekovaných hran

Název textury	skupina vypadek	skupina zdrvyp	skupina zdr
<b>B složka</b>	260,8 ± 182,6	594,2 ± 264,5	1195,2 ± 469,1
<b>G složka</b>	179,9 ± 149,1	456,4 ± 225,8	1182,9 ± 436,4

#### 2.4.4 Hodnocení funkčnosti metody

Jak je z výsledků obou statistik patrné, tato metoda vycházející z hranové reprezentace se jeví se jako vhodná k detekci oblastí výpadku nervových vláken. Je však nutno podotknout že v některých případech, zvláště ve větších vzdálenostech od slepé skvrny je i u zdravé tkáně žíhání již nezřetelné a proto je tato oblast mylně detekována jako výpadek. Jediným viditelným rozdílem mezi zdravou a nemocnou tkání je v tomto případě jas. Proto by tato metoda mohla být účinnější v kombinaci s metodou hodnocení jasu, která je popsána v následující kapitole.

## 2.5 Metoda hodnocení jasu

### 2.5.1 Teoretický úvod

Tato metoda je založena na jednoduchém poznatku, že oblasti s výpadkem nervových vláken jsou obecně tmavší než oblasti se zdravou tkání. Z měření průměrných hodnot jasů ve výřezech z kapitoly 2.3.2 vyšlo najevo, že střední hodnota jasu při výpadku (skupina A) je cca o 18 stupňů šedi nižší než u zdravé tkáně nemocného oka (skupina B). Průměrná hodnota jasů výřezů u zdravého oka (skupina C) je ještě o cca 5 stupňů šedi vyšší než zdravá tkáň nemocného oka.

Úroveň šedi se mezi různými snímky liší. Dokonce se bude patrně lišit i mezi jednotlivými měřeními u stejného pacienta. To je dáno obtížně ovlivnitelnými faktory (např. velikost zornice, transparentnost prostředí oka atd.). Nelze tedy jednoduše nalézt vztah mezi absolutní hodnotou stupně šedi a tloušťkou vrstvy nervových vláken. Proto se určí střední hodnota stupně šedi v obraze a od ní se počítají rozdíly v konkrétních pixelech. Pokud má daný pixel hodnotu šedi nižší než je průměrná hodnota šedi v celém obraze o více než je zvolená mez, je označen jako tkáň obsahující výpadek ve vrstvě nervových vláken.

### 2.5.2 Návrh programu

Postup metody je následující: Nejprve se vytvoří oblast zájmu podle kapitoly 3.1.2. Z této oblasti se ještě vyloučí cévy (viz kapitola 3.1.1). Poté se v analyzovaném snímku sníží šum pomocí průměrování hodnot ve zvolené masce. V programu velikost masky určuje proměnná  $R\_jasu$  – výsledná velikost masky je dvojnásobná oproti této proměnné. Ve výchozím nastavení je maska pro průměrování nastavena na velikost  $6 \times 6$  pixelů. Tím se eliminují případné, náhodné výkyvy hodnot jasu. Z takto upraveného obrazu se vypočítá průměrná hodnota jasu. Poté se určí prahová hodnota. Tato hodnota určuje o kolik stupňů šedi může mít daný pixel nižší hodnotu oproti průměrné hodnotě šedi, aby byl ještě klasifikován jako zdravá tkáň.

### 2.5.3 Hodnocení funkčnosti metody

Tato metoda byla zkoušena na sedmi snímcích obsahující výpadkem ve vrstvě nervových vláken a stejném počtu snímků zdravého oka. Ve zvolené oblasti zájmu dokáže celkem bezpečně detekovat rozsáhlý výpadek. V některých případech je však detekována i tmavší zdravá tkáň mylně jako výpadek. Je také nutno podotknout, že směrem k periférii snímků jas i u zdravé tkáně klesá. Proto tato metoda není vhodná pro analýzu okrajových částí snímku. Tato metoda i přes svou jednoduchost překvapivě podává srovnatelné výsledky s oběma výše popsány metodami.

# 3 PROGRAM PRO AUTOMATICKOU DETEKCI OBLASTÍ VÝPADKU NERVOVÝCH VLÁKEN

V rámci diplomové práce byl navržen, realizován a vyhodnocen program pro automatickou detekci oblastí výpadku nervových vláken.

## 3.1 Návrh programu

Vstupními snímky mohou být celobarevné RGB, snímky snímané přes filtr BPB45, případně jako sloučená složka GB snímku snímaného přes filtr BPB45, získána podle vzorce 1.1. Typ snímku je nutno označit před samotným načtením snímku, aby program mohl podle tohoto nastavení provést určité modifikace. Samotná analýza pracuje v několika krocích.

### 3.1.1 Segmentace a vymaskování cévního řečiště


Z důvodu, že cévní řečiště má daleko větší kontrast než nervová vlákna, je nutno cévní řečiště detekovat a následně vymaskovat. Nedodržením tohoto postupu by analyzované oblasti obsahující cévní řečiště byly pro detekci nervových vláken prakticky nepoužitelné. Proto je prvním krokem segmentace cévního řečiště.

#### Segmentace cévního řečiště

Funkce pro segmentaci cévního řečiště<sup>1</sup> byla převzata z [6]. Pracuje s využitím přístupů přizpůsobené filtrace a následného prahování vedoucího k vytvoření binárního obrazu. Přizpůsobená filtrace využívá korelace mezi profilem cévy znázorňujícím distribuci jasu napříč cévou a 2D filtračními maskami. Návrh těchto masek vychází z aproximace jasových profilů cév pomocí Gaussovy křivky. Podle [6] jsou navrženy celkem 3 masky – pro detekci malých cév, středě velkých cév a velkých cév s reflexem. Masky byly navrženy pro celobarevné snímky RGB. Při použití vstupních snímků pořízených přes filtr BPB45 nastává problém z důvodu výrazné parazitní detekce nervových vláken. Proto je ve výchozím nastavení aktivní pouze maska pro detekci středních cév. Masky jsou postupně rotovány ve dvanácti různých směrech. Výsledek filtrace je prahován, poté se odstraní malé nespojené objekty vzniklé převážně právě chybnou detekcí výraznějších nervových vláken. Tímto postupem vznikne binární hranová reprezentace cévního řečiště, uložená do proměnné s názvem *BW\_civy* (obr. 3.1).

---


<sup>1</sup>tato funkce je uložena na příloženém CD: `./program/vessel.m`




1a)



2a)



1b)




2b)




3a)



4a)



3b)



4b)

Obr. 3.1: Segmentace snímků snímaných přes filtr BPB45 je v levém sloupci, segmentace stejných snímků snímaných bez filtru je v pravém sloupci. U celobarevných snímků (bez filtru) jsou dosaženy zřetelně lepší výsledky.

Jako vstupní obraz pro segmentaci cév je zvolena u RGB snímků i snímků pořízených přes filtr G složka ze vstupního obrazu. Jak je patrné z obr. 3.1, lepších výsledků je dosaženo při segmentaci z G složky celobarevného RGB snímku než použitím G složky ze snímku snímaného přes filtr. Cévy v G složce RGB snímku mají vyšší kontrast, naopak nervová vlákna jsou méně výrazná. Naopak u G složky ze snímku pořízeného přes filtr často dochází ke dvěma nežádoucím extrémům. Z důvodů nižšího kontrastu cév nejsou některé části cév detekovány a naopak z důvodů vyššího kontrastu nervových vláken jsou některá nervová vlákna mylně detekována jako céva. Lze tedy říci, že pro detekci cévního řečiště jsou jednoznačně vhodnější RGB snímky.

### Vymaskování cévního řečiště

Dalším krokem je vymaskování cévního řečiště. Vymaskování v obraze probíhá na pixelech označených jako céva. Protože však šířka segmenovaných cév je menší než skutečná šířka cév v obraze, je nutno binární cévy dilatovat. Pro samotné vymaskování byly navrženy dvě metody:

**a) Metoda nejbližšího souseda** – při použití této metody jsou pixely cévního řečiště nahrazeny pixely z okolí metodou nejbližšího souseda. To znamená, že každému pixelu označenému jako céva je přiřazen nejbližší pixel obrazu, který jako céva označen není. Výsledek je zobrazen na obr. 3.2c a jeho programová realizace je následující:

```

interpolovany_obraz = vstupni_obraz_detekce_nervu;
BW_cevy = bwmorph(BW_cevy, 'dilate', 6);
BW_cevy = ~BW_cevy;
[D,L] = bwdist(~BW_cevy);
index_cevy = L.*BW_cevy;
[X,Y] = size(vstupni_obraz_detekce_nervu);
R = 64;
for o = 1+R:X-R
    for p = 1+R:Y-R
        if BW_cevy(o,p) > 0
            a = index_cevy(o,p)/X;
            y = floor(a)+1;
            x = (mod(index_cevy(o,p),X));
            interpolovany_obraz(o,p) = interpolovany_obraz(x,y);
        end
    end
end
end


```

K vymaskování je potřebná binární reprezentace cévního řečiště  $BW\_cevy$ . Pomocí příkazu `bwdist` se vytvoří proměnné  $D$  a  $L$ . Jejich funkci osvětluje příklad:

0	0	0	0	0	1,41	1,00	1,41	2,23	3,16	7	7	7	7	7
0	1	0	0	0	1,00	0	1,00	2,00	2,23	7	7	7	7	19
0	0	0	0	0	1,41	1,00	1,41	1,00	1,41	7	7	7	19	19
0	0	0	1	0	2,23	2,00	1,00	0	1,00	7	7	19	19	19
0	0	0	0	0	3,16	2,23	1,41	1,00	1,41	7	19	19	19	19

$, D =$        $, L =$

Do  $D$  se uloží vzdálenostní mapa matice  $BW\_cevy$ . Každý element matice  $L$  obsahuje lineární index nejbližšího nenulového prvku matice  $BW\_cevy$ . Do proměnné  $index\_cevy$  se uloží tyto indexy pouze na pozicích cév. Ve dvojitém cyklu `for` se postupně pro každý pixel cévy vytvoří do proměnných  $x$  a  $y$  x-ová a y-ová souřadnice nejbližšího pixelu, který cévu neobsahuje. Poté pixel z původního obrazu s touto souřadnicí nahradí pixel cévy.



Obr. 3.2: Ukázka vymaskování cévního řečiště metodou nejbližšího souseda, a) vstupní snímek, b) binární reprezentace cévního řečiště, c) vymaskované cévní řečiště

**b) Metoda průměrování okolí** Tato metoda pracuje tak, že pro pixel označený jako céva se vypočítá průměr jasů z jejího okolí – a to pouze z těch oblastí v jejím okolí, které jako céva označeny nejsou. Tímto postupem se tedy získá průměrná hodnota jasu okolní tkáně neobsahující cévy. Tato hodnota se pak vloží na původní místo pixelu označeného jako céva.

Metoda průměrování se však ukázala jako méně účinná a navíc podstatně více výpočetně náročná. Porovnáním spekter výřezů tkání s vymaskovanými cévami bylo konstatováno, že dokonalejší odstranění cév ze spektra umožňuje metoda nejbližšího souseda. Proto v další práci byla používána jen tato metoda.

### 3.1.2 Automatická detekce oblasti zájmu


Dalším krokem je automatické určení oblasti zájmu pro následnou detekci nervových vláken. Diagnosticky nejvýznamnější oblast pro hodnocení výpadku nervových vláken je oblast v okolí slepé skvrny směrem ke žluté skvrně. Proto je pro určení oblasti zájmu rozhodující určit správně střed a poloměr slepé skvrny. K tomu byl použit algoritmus podle [7]. Vychází se z poznatku, že slepá skvrna má ve snímku nejvyšší jas, proto se přibližný střed určí z lokálního maximálního jasu masky o rozměrech  $30 \times 30$  pixelů. Poté se pomocí Cannyho detektoru určí hrany v okolí slepé skvrny. Aproximovaná kružnice odpovídající poloze okraje slepé skvrny se určí z výstupu hran z Cannyho detektoru pomocí Houghovy transformace. Podle polohy slepé skvrny se vytvoří oblast zájmu (obr. 3.3a - fialová oblast). Podrobnější popis tvorby oblasti zájmu je v kapitole 3.2.1.

Veškerá následující analýza probíhá na vymaskovaném obraze a jen ve vyznačené oblasti zájmu. Značení výsledků je pro větší názornost realizováno na vstupním obraze obsahujícím cévy.

### 3.1.3 Určení kroku analýzy, značení cév a oblastí s vysokým podílem neurčitosti

Všem třem analýzám lze individuálně určit krok, kterým budou jednotlivé analýzy probíhat. Výchozím nastavením je u všech krok 16. Dalším nastavením, které lze u všech analýz realizovat, je podíl neurčitosti. Tato hodnota udává, kolik procent vymaskovaných pixelů může analyzovaný pixel ve svém okolí maximálně mít, aby ještě proběhla daná analýza. Tímto se má zajistit, aby byly vyřazeny oblasti s významným podílem neurčitosti. Velikost okolí pro určení neurčitosti je u směrové spektrální analýzy dána proměnnou  $R_{sp}$ , u detekce založené na hranové reprezentaci proměnnou  $R_{LoG}$ . U analýzy jasu je toto okolí zvoleno jako menší z hodnot  $R_{sp}$  a  $R_{LoG}$ . Ve výchozím nastavení je u všech analýz nastaven podíl neurčitosti





Obr. 3.3: a) oblast zájmu, na které probíhá analýza, je vyznačena fialově, b) detail analýzy – žlutý rámeček

na 40 procent. Tato hodnota se jeví jako vhodný kompromis mezi přiměřenou mírou neurčitosti a akceptovatelným zmenšením plochy pro analýzu.

Poté proběhne značení cév a oblastí s neurčitostí vyšší, než je nejnižší hodnota povoleného podílu neurčitosti. Cévy se vyznačí na oblastech odpovídajících matici  $BW\_cevy$  a znázorní se tmavě modrou barvou. Z matice  $BW\_cevy$  se vypočítají také hodnoty neurčitosti a pixely s vysokým podílem neurčitosti se znázorní světle modrou barvou. Ve zbylých oblastech oblasti zájmu bude probíhat samotná detekce výpadku nervových vláken (viz obr. 3.3b).

### 3.1.4 Automatická detekce výpadku ve vrstvě nervových vláken

Samotná detekce se skládá ze tří výše popsaných a na sobě nezávislých přístupů: směrové analýzy spekter, analýzy založené na hranové reprezentaci a analýzy jasu. Z výstupů jednotlivých analýz se vytvoří matice příznaků, které odpovídají hodnotě hledaného příznaku v daném okolí pixelu. U směrové analýzy spekter je příznakem maximální rozdíl energií ve výsečích spektra, u analýzy založené na hranové reprezentaci je to prostorová hustota hranových pixelů v definovaném okolí pixelu a u analýzy jasu se jedná o průměrnou hodnotu jasu v předdefinovaném okolí.

Pro každou analýzu jsou předem určeny tři hraniční hodnoty, které rozdělí výsledné příznaky do čtyř intervalů. Z každé matice příznaků se vytvoří částečná matice výsledků, která obsahuje hodnoty 0 – 3 vytvořené podle toho, do kterého intervalu daný příznak patří. Nule odpovídá s největší pravděpodobností výpadek, trojce

zdravá tkáň. Ze tří částečných matic výsledků se prostým součtem vytvoří celková matice výsledků, obsahující hodnoty 0 – 9. Z této matice se vytvoří výsledný obraz, kde oblasti obsahující hodnoty  $< 5$  se označí červeně jako výpadek ve vrstvě nervových vláken a oblasti s hodnotami  $\geq 5$  se označí zeleně jako zdravá tkáň (viz obr. 3.3b a porovnání výsledků v kap. 4).

Bližší vysvětlení zobrazení jednotlivých analýz z obr. 3.3b pro jednu konkrétní analyzovanou oblast je znázorněno na obr. 3.4.


<b>1</b>	<b>2</b>	<b>3</b>
<b>4</b>	<b>5</b>	<b>6</b>
<b>7</b>	<b>8</b>	<b>9</b>

Obr. 3.4: vysvětlení k zobrazení výsledků detekce v obr. 3.3b

Centrální pixel má hodnotu 5. Pixel 1 je výsledek spektrální analýzy, 3 LoG analýzy a 7 analýzy jasu. Jedná se o konkrétní hodnoty z matic částečných výsledků pro analyzovanou oblast se středem v bodě 5. Jak již bylo popsáno, tyto hodnoty mohou nabývat čtyř různých hodnot. Těmto hodnotám byly přiřazeny barvy - pro nulu červená, pro jedničku oranžová, pro dvojku žlutá a pro trojku zelená. Prostým součtem těchto třech hodnot se pixely 5, 6, 8 a 9 označí zeleně jako zdravá tkáň pro součet  $\geq 5$  nebo červeně jako oblast výpadku nervových vláken pro součet  $< 5$ .

## 3.2 Manuál k programu

Po spuštění programu<sup>2</sup> se objeví pracovní plocha, která je rozdělena na několik úseků (viz obr. 3.5). Ihned po spuštění je program nastaven do jednoduchého režimu, tzn. není zobrazen úsek 5. Program je navržen tak, aby uživatel nemusel téměř nic nastavovat. Celá analýza probíhá automaticky, jen po spuštění programu je uživatel povinen zadat, jaký typ vstupního snímku má v úmyslu načíst. Na výběr jsou tři varianty, jak je zobrazeno na obr. 3.6: celobarevný snímek RGB, snímek snímáný přes filtr BPB45 nebo G či B složku snímku snímaného přes filtr BPB45. Přednastaven je plně barevný snímek RGB. Pokud bude načítán tento typ snímku, není nutno nastavení provést. Poté již nic nebrání samotnému načtení vstupního snímku. To se děje pomocí hlavního menu na horní liště: **Soubor – Otevřít**.



Obr. 3.5: Schématické znázornění rozložení pracovní plochy: 1 – vstupní snímek, 2 – zobrazení mezivýsledků a následný výsledný analyzovaný snímek, 3 – ovládací panel pro automatickou analýzu, 4 – panel pro nastavení jednotlivých kroků analýzy, 5 – panel pro pokročilé funkce, 6 – informační panel

Po zvolení snímku program porovná, jestli se počet barevných složek načítaného snímku shoduje s výše zvoleným typem snímku – u snímku RGB i snímáného přes filtr se očekává třísložkový snímek, u snímku s G nebo B složkou jednosložkový. Jestliže se počet načítaných a očekávaných složek shoduje, je snímek načten do

<sup>2</sup>program je nutno spustit ve vývojovém prostředí MATLAB s nainstalovaným *Image processing toolbox*, spuštěním funkce `diplomova_prace_xgazar03.m`, která je uložena na přiloženém CD v adresáři: `./program/diplomova_prace_xgazar03.m`

úseku 1 a v informačním panelu se objeví hláška: **Snímek načten**. Pokud není nalezena shoda, snímek se nenačte a v informačním panelu se objeví: **Nejedná se o RGB snímek**, případně **Nejedná se o šedotónový snímek**.

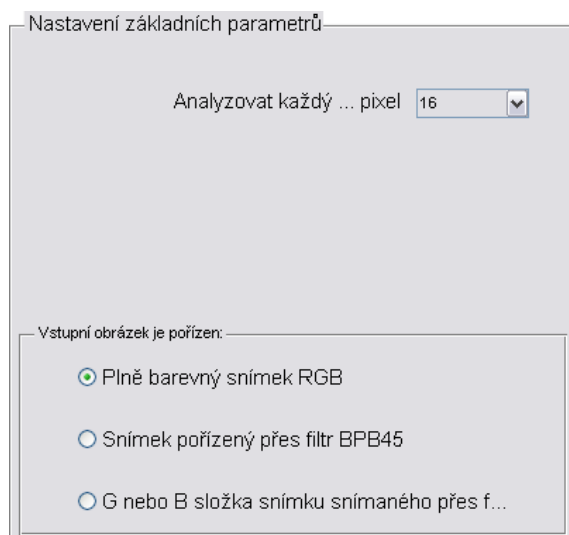
Po úspěšném načtení vstupního snímku se zpřístupní tlačítko **Celková analýza**<sup>3</sup>. Jeho stisknutím se spustí automatická detekce oblastí výpadku nervových vláken. Pod načtený vstupní snímek do panelu č.2 se postupně zobrazují jednotlivé mezivýsledky analýzy: detekované cévy, obraz s vymaskovanými cévami, automatické určení oblasti zájmu analýzy a konečně výsledek. Protože je toto okno poměrně malé, je pro lepší názornost po skončení výpočtu výsledek zobrazen i do samostatného okna.

### 3.2.1 Nastavení jednotlivých kroků analýzy

Program je navržen pro automatickou detekci bez nutnosti nastavování parametrů. Pokud se však uživatel rozhodne, může změnit řadu parametrů u jednotlivých kroků analýzy. Nastavení se volí pomocí horní lišty v sekci **Nastavení** a zobrazuje se do panelu č.4. Nyní bude uveden přehled nastavení jednotlivých kroků analýzy.

#### Nastavení celkové analýzy

Jak již bylo zmíněno, před spuštěním samotné analýzy je nutno nastavit typ snímku. Dále je možno pomocí překryvného (pop-up) menu **Analyzovat každý ... pixel** nastavit krok analýzy, což znamená krok, s nímž budou všechny tři analýzy v ose x a y probíhat. V původním nastavení je nastaven každý šestnáctý pixel. Se zmenšujícím se krokem roste doba výpočtu.



Obr. 3.6: Menu nastavení pro celkovou analýzu snímku

<sup>3</sup>šedým pozadím okolo textu budou pro jednodušší orientaci v textu udávány názvy jednotlivých ovládacích prvků

## Nastavení segmentace cév

Segmentace cév je problematická hlavně u snímků snímaných přes filtr BPB45. Proto je aktivována jen filtrační maska č.2 – maska pro střední cévy. Při aktivaci ostatních dvou masek sice budou nalezeny i menší cévy a celé cévní řečiště bude vysegmentováno dokonaleji, avšak za cenu nepřiměřeně časté falešné detekce nervových vláken označených jako céva. U celobarevných snímků je situace lepší, proto mohou být aktivovány všechny tři filtrační masky. Pro mazání drobných artefaktů vzniklých převážně právě falešnou detekcí výrazných nervových vláken slouží posuvník **Smazat objekty menší než**, který smaže v binárním obraze segmentovaných cév všechny objekty menší než zvolená mez.

Dále je zde blok pro nastavení filtrační masky č.2. Je možno nastavit proměnnou **ax**, která určuje velikost masky. Také je možno nastavit proměnnou **sigma**, která udává hodnotu poloviny šířky Gaussovy křivky v polovině její maximální výšky.

Nastavení segmentace cév

Aktivovat filtrační masky:

- ☐ Aktivní filtrační maska č.1 - malé cévy
- ☒ Aktivní filtrační maska č.2 - střední cévy
- ☐ Aktivní filtrační maska č.3 - cévy s reflexem

Smazat objekty menší než:

1   500 250

Nastavení filtru 2

Proměnná ax 6

Proměnná axes

1   10 3.8

Původní nastavení

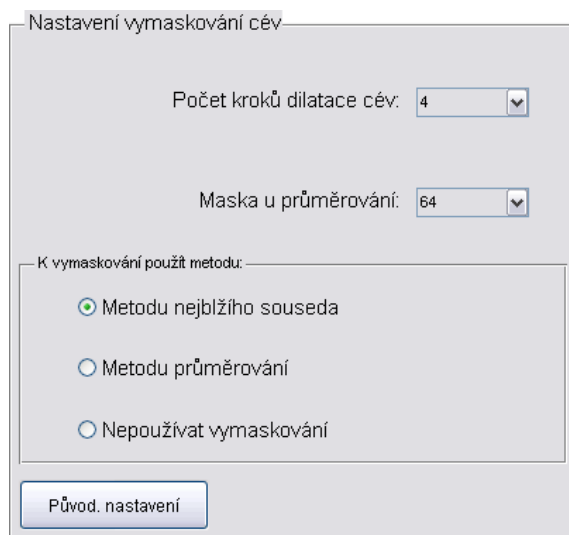
Obr. 3.7: Menu nastavení pro segmentaci cév

## Nastavení vymaskování cév

V menu nastavení vymaskování cév (obr. 3.8) je možno zvolit, jaká metoda bude pro vymaskování použita. Přednastavena je metoda nejbližšího souseda, která se ukázala ve většině případů jako vhodnější pro následnou analýzu. Kromě této metody je možno ještě zvolit metodu průměrování okolí, případně vymaskování zakázat. Pokud je vymaskování zakázáno, bude následná analýza probíhat na obraze obsahujícím kontrastní cévy, čímž bude analýza značně zkreslena.

Dalším prvkem který je možno nastavit, je **Počet kroků dilatace cév**. Tato hodnota určuje, kolikrát bude binární obraz cév dilatován, tzn. jak velké okolí cév bude označeno jako céva.

Hodnota s názvem **Maska u průměrování** udává polovinu délky strany masky, která bude použita při metodě průměrování okolí pro výpočet jednotlivých vymaskovaných pixelů.



Obr. 3.8: Menu nastavení pro vymaskování cév

### Nastavení pro výběr oblasti zájmu

Oblast, na které bude probíhat analýza výpadku nervových vláken, je zvolena automaticky. Tato oblast může být také vybrána manuálně vyznačením hraničních bodů do vstupního snímku. Tato eventualita se volí stisknutím tlačítka **Manuální výběr ROI**. Výslednou podobu oblasti zájmu vytvořenou automatickou detekcí je možno ovlivnit pomocí pěti posuvníků, viz. obr. 3.9.

Posuvník s názvem **Zvětšit oblast optického disku o ... pixelů** zvětší poloměr kružnice detekovaného optického disku o zvolený počet pixelů. Na obr. 3.10 je výsledná oblast zájmu vymezena uvnitř oranžové hranice. Optický disk detekovaný pomocí Houghovy transformace je znázorněn černou kružnicí. Rozdíl v poloměru této kružnice s poloměrem oranžové půlkružnice udává právě tento posuvník. Význam dalších posuvníků je vysvětlen na obr. 3.10:

Nastavení pro výběr oblasti zájmu

Automatický výběr ROI      Manuální výběr ROI

Zvětšit oblast optického disku o ... pixelů

0    100    30

Posun ROI o ... pixelů v ose x

-500    500    0

Počet pixelů obsahující kratší úsečka v ose y

0    600    300


Počet pixelů obsahující delší úsečka v ose y

0    500    100

Šířka ROI v ose x [pixelů]

200    1200    700

Obr. 3.9: Menu nastavení pro výběr oblasti zájmu



Obr. 3.10: Význam posuvníků z obr. 3.8: a) Posun ROI o ... pixelů v ose x ,  
b) Počet pixelů obsahující kratší úsečka v ose y , c)  
Počet pixelů obsahující delší úsečka v ose y , d) Šířka ROI v ose x [pixelů]

## Nastavení spektrální analýzy

Tento ovládací panel je zobrazen na obr. 3.11. Při nastavení spektrální analýzy je důležitý tvar masky výseče. Nastavení tvaru masky výseče obsluhuje horních pět překryvných (pop-up) menu, která ovlivňují pět vstupních proměnných funkce *spektrální\_analyza\_vysece*, viz kap. 2.3.3. Hodnota z menu **Polovina strany spektra** je proměnná  $R_{sp}$  a určuje velikost výřezů, ze kterých se budou vytvářet 2D spektra. Výřez bude mít rozměr  $x \times x$ , kde  $x = 2 \cdot R_{sp} + 1$ , tzn. v předdefinovaném nastavení bude mít výřez rozměr  $129 \times 129$  pixelů. **Počet výsečí** je proměnná  $n$  a udává úhel výseče. **Krok výseče [°]** zastupuje proměnnou *krok* a určuje velikost kroku při otáčení výseče. **Poloměr od...** zastupuje proměnnou *od* a **Poloměr do...** proměnnou *do*. Tlačítko **Vykreslit** vykreslí podobu masky výseče podle aktuálního nastavení.

Nastavení spektrální analýzy

Polovina strany masky: 64

Úhel výseče: 22,5°

Krok výseče [°]: 7.5

Krok analýzy: 16

Analyzovat do...[%] cév v masce: 40

Poloměr od...: 1/16

Poloměr do...: 1/3

Vykreslit

Hranice zdravé tkáně: 0 | 4 | 1.8

Hranice podezření na výpadek: 0 | 4 | 1.65

Hranice výpadku: 0 | 4 | 1.5

Původní nastavení

Obr. 3.11: Menu nastavení pro spektrální analýzu

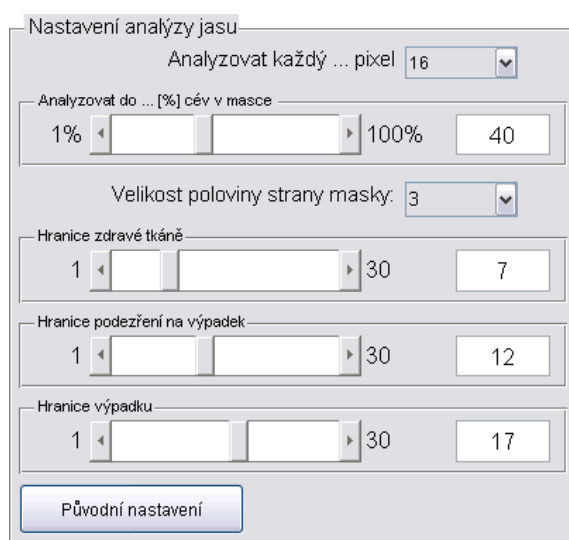
Význam tří posuvníků umístěných ve spodní polovině menu – **Hranice zdravé tkáně**, **Hranice podezření na výpadek** a **Hranice výpadku**, je zřejmý. Jedná se o prahy pro rozdělení vypočtených maximálních rozdílů energií ve výsecích spekter do jedné ze čtyř klasifikačních skupin z hlediska detekce oblasti výpadku nervových vláken.



## Nastavení analýzy jasu

Ovládací panel pro nastavení analýzy jasu je zobrazen na obr. 3.12. Pomocí menu **Analyzovat každý ... pixel** je možno zvolit krok analýzy jasu. Kolik může být v masce procent vymaskovaných cév, aby analýza jasu proběhla, udává posuvník s názvem **Analyzovat do ... [%] cév v masce**. Proměnná  $R_{jasu}$ , která udává jak velkou maskou bude průměrován jas obrazu, určuje překryvné menu **Velikost poloviny strany masky**.

Posuvníky **Hranice zdravé tkáně**, **Hranice podezření na výpadek** a **Hranice výpadku** určují hranice pro klasifikaci výpadku. Např. pokud bude jas analyzovaného pixelu vyšší, než průměrný jas v oblasti zájmu mínus **Hranice zdravé tkáně**, bude tento pixel označen jako zdravá tkáň.



Obr. 3.12: Menu nastavení pro analýzu jasu

## Nastavení hranové detekce pomocí LoG

Vzhled ovládacího panelu pro nastavení analýzy vycházející z hranové reprezentace je zobrazen na obr. 3.13. Také při této analýze můžeme volit krok, s jakým bude analýza probíhat. Posuvník **Vymazat menší objekty než ... pixelů** vymaže z binární hranové reprezentace všechny objekty, které jsou menší než zvolená mez. Výchozí hodnota je 5. Posuvník **Analyzovat do ... [%] cév v masce** udává, kolik může být v masce procent vymaskovaných cév, aby analýza proběhla. Menu s názvem **Polovina strany masky R-LoG** určuje velikost masky, ze které bude kalkulována prostorová hustota detekovaných hran. Ve výchozím nastavení je  $R_{LoG}$  nastavena na hodnotu 64, rozměr masky je tedy  $128 \times 128$ .

Nastavení LoG analýzy

Analyzovat každý ... pixel 16

Vymazat menší objekty než ... pixelů

1 50 5

Analyzovat do ... [%] cév v masce

1% 100% 40

Poloměr masky R\_Log 64

Min. % hranových pixelů v ROI pro zdr. tkáň

1% 20% 6

Hranice podezření: ... [%] hodnoty zdr. tkáně

1% 100% 95

Hranice výpadku: ... [%] hodnoty hranice podezření

1% 100% 95

Původ. nastavení


Obr. 3.13: Ovládací panel pro nastavení analýzy vycházející z hranové reprezentace

Posuvník **Min. % hranových pixelů v ROI pro zdr. tkáň** udává kolik procent hranových pixelů musí být minimálně v analyzované masce, aby byl pixel analyzovaného snímku odpovídající poloze středu masky označen jako zdravá tkáň. Posuvník **Hranice podezření: ... [%] hodnoty zdr. tkáně** určuje druhou hodnotu prahu. Tato hodnota se určí jako zvolený počet procent z prahu pro zdravou tkáň. Ve výchozím nastavení je zvoleno 95 % ze 6 %, což je 5,7 %. Na stejném principu pracuje poslední posuvník **Hranice výpadku: ... [%] hodnoty hranice podezření**, který určuje hodnotu prahu pro výpadek. Ten se určí jako procentuální vyjádření předešlého prahu. Ve výchozím nastavení je nastaveno 95 % z 5,7 %, což je 5,415 %.


## 4 VÝSLEDKY DETEKCE OBLASTÍ VÝPADKU VE VRSTVĚ NERVOVÝCH VLÁKEN

Jako vstupní snímky pro detekci byly použity B složky ze snímku snímaného přes filtr BPB45. Značení je provedeno tak, že modré oblasti jsou cévy, světle modré jsou oblasti s vysokou mírou neurčitosti, zeleným oblastem odpovídá zdravá tkáň a červeným tkáň s výpadkem ve vrstvě nervových vláken.


Na obr. 4.1 je zobrazen výsledek detekce u zdravého oka, na zbylých snímcích jsou zobrazeny výsledky pro oko obsahující výpadek ve vrstvě nervových vláken.




Obr. 4.1: Ukázka výsledné detekce u snímku zdravého pacienta




Obr. 4.2: Snímek s názvem 1B s vyznačením výpadu ve vrstvě nervových vláken oftalmologem



Obr. 4.3: Snímek s názvem 1B s vyznačením výpadu ve vrstvě nervových vláken automatickou detekcí – červená barva znázorňuje výpadek.




Obr. 4.4: Snímek s názvem 3B s vyznačením výpadu ve vrstvě nervových vláken oftalmologem




Obr. 4.5: Snímek s názvem 1B s vyznačením výpadu ve vrstvě nervových vláken automatickou detekcí – červená barva znázorňuje výpadek.





Obr. 4.6: Snímek s názvem 4B s vyznačením výpadu ve vrstvě nervových vláken oftalmologem



Obr. 4.7: Snímek s názvem 1B s vyznačením výpadu ve vrstvě nervových vláken automatickou detekcí – červená barva znázorňuje výpadek.

## 4.1 Diskuze k výsledkům

Program byl primárně optimalizován pro analýzu snímků snímaných přes filtr BPB45. Pro volbu tohoto typu snímku jsme byli donuceni z toho důvodu, že jsme neměli k dispozici dostatek celobarevných snímků s nízkou kompresí obsahující výpadek ve vrstvě nervových vláken. Nervová vlákna ve snímcích snímaných přes filtr jsou zřetelná, avšak samotná automatizovaná analýza je provázena řadou problémů a omezení. Horších výsledků se dosahuje hned při segmentaci cévního řečiště. Projevují se zde více než u segmentace celobarevných RGB snímků dva nežádoucí jevy: Detekce cévního řečiště je méně dokonalá a obsahuje více artefaktů vzniklých falešnou detekci výrazných nervových vláken. Falešná detekce nervových vláken je patrná zvláště u snímků zdravých pacientů, kde je vrstva nervových vláken zřetelnější (viz obr. 4.1). Také detekce žluté skvrny je problematičtější, protože je odfiltrována složka R, která je pro tuto detekci nejvhodnější, musí být použita méně vhodná složka G.

Bylo také zkoušeno různě předzpracování snímků – optimalizace histogramu a zvýraznění kontrastu. Tyto úpravy ovšem nepřinesly žádné výrazné zlepšení výsledné detekce výpadku ve vrstvě nervových vláken, a proto od jejich použití bylo upuštěno.

Pro detekci rozsáhlejších výpadků pracuje program poměrně spolehlivě. Problém může představovat drobný, nevýrazný výpadek. Je to dáno tím, že pro směrovou spektrální analýzu a pro detekci pomocí hranové reprezentace je k výpočtu daného pixelu použito jeho okolí  $129 \times 129$  pixelů. Z tohoto důvodu je rozlišovací schopnost celkové analýzy omezena. Je možno pochopitelně rozměr masek snížit, avšak za cenu podstatného zhoršení přesnosti analýzy.

Lze konstatovat, že v předdefinované oblasti zájmu program pracuje poměrně spolehlivě. Pro uvedení do praxe by bylo žádoucí tuto oblast rozšířit. Zvětšení vyšetřované oblasti se současným zachováním přesnosti analýzy je však obtížně realizovatelné. Příčina těchto obtíží je v tom, že prostorová distribuce nervových vláken v analyzovaných obrazech není homogenní. Tato nehomogenita je dána fyziologií sítnice – na periférii je jejich koncentrace nižší. Proto v těchto oblastech program často analyzuje fyziologický stav chybně jako patologický a oblast označí jako výpadek ve vrstvě nervových vláken. Odstranění tohoto problému by však nebylo triviální. Bylo by zřejmě nutno použít metody založené na vyšším stupni rozhodování, například pomocí empiricky vytvořených, prostorově variantních váhovacích map. Tyto mapy by v závislosti na pozici měnily hraniční hodnoty.

Podobný problém se také často vyskytuje v blízkosti žluté skvrny. I přesto, že v této oblasti je hustota nervových vláken nejvyšší, žihání zde není patrné. To má za následek, že program často tuto oblast paradoxně detekuje jako výpadek. K tomuto jevu přispívá také to, že tato oblast vykazuje nižší hodnoty jasu. Také v tomto případě se jako řešení jeví použití váhovacích map.

## 5 Závěr

Náplní této diplomové práce byla analýza barevných snímků sítnice pořízených digitální fundus kamerou z pohledu detekce oblastí výpadku ve vrstvě nervových vláken. Projekt byl sponzorován výzkumným centrem DAR (č. 1M6798555601).

Práci je možno rozdělit do dvou hlavních etap. První etapou byla experimentální část, v níž byly hledány různé přístupy potenciálně vhodné pro rozlišení textur obsahujících oblasti s nervovými vlákny od textur s výpadkem ve vrstvě nervových vláken. Navržené přístupy byly podrobně zkoumány. Byla hodnocena jejich schopnost tyto typy textur od sebe rozeznat. Ve druhé etapě byl z přístupů, které se ukázaly jako vhodné, navržen rutinně použitelný program sloužící pro automatickou detekci oblastí výpadku ve vrstvě nervových vláken.

Postupně byly zkoušeny čtyři přístupy. Prvním přístupem byla analýza metodou matice co-occurrence. Byla testována samotná co-occurrence matice a čtyři její příznaky, zda se najde hodnotící parametr pro rozlišení zdravé tkáně od tkáně s výpadkem. To se však nepodařilo, a proto byla tato metoda označena jako nevyhovující. Další tři testované metody se ukázaly jako vhodnější – směrová spektrální analýza, přístup vycházející z hranové reprezentace a metoda hodnocení jasu.

Poté byl navržen, realizován a vyhodnocen program pro automatickou detekci oblastí výpadku vrstvy nervových vláken. Účinnost tohoto programu lze shrnout konstatováním, že v předdefinované oblasti zájmu program pracuje poměrně spolehlivě. Úspěšnost detekce do značné míry závisí na kvalitě segmentace cévního řečiště a s ním spojeného vymaskování cévního řečiště. Následná detekce vyskytujících se nervových vláken se zdaří, pokud jsme schopni v textuře okem rozeznat žíhání. Potom i program toto žíhání detekuje a oblast označí jako zdravou tkáň. Problematikou je detekce v některých oblastech snímku (zvláště mimo předdefinovanou oblast zájmu), kde i přes přítomnost nervových vláken není žíhání patrné. V tomto případě vzniká reálné nebezpečí falešně negativního výsledku. Pro zpřesnění detekce v těchto oblastech by bylo zřejmě nutno použít metody založené na vyšším stupni rozhodování – například pomocí váhovacích map.



# Literatura

- [1] JAN, J. *Medical Image Processing, Reconstruction and Restoration - Concepts and Methods*. CRC Tylor and Francis, New York 2005. ISBN 0-8247-5849-8.
- [2] FLAMMER, J. *Glaukom*. Nakladatelství TRITON s.r.o., Praha, 2003. ISBN 80-7254-351-2
- [3] TUCERYAN, M., JAIN, A. K. *The Handbook of Pattern Recognition and Computer Vision - Texture Analysis*. World Scientific Publishing Co., 1998.
- [4] BAŠTINEC, J. *Pravděpodobnost a matematická statistika*. Skripta v elektrotechnické podobě. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav matematiky, 2007.
- [5] PARKER, JR. *Algorithms for Image Processing and Computer Vision*. New York, John Wiley & Sons, 1997.
- [6] ODSTRČILÍK, J. *Segmentation of vessel structure in retinal images by matched filtering*. Diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2008.
- [7] MALÍNSKÝ, M. *Segmentace významných objektů v barevných oftalmologických obrazech*. Diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2008.

# Seznam příloh

<b>A</b>	<b>Tabulky</b>	<b>74</b>
A.1	Tabulky pro cooc . . . . .	74
A.2	Rozdíly energií u spektrální analýzy . . . . .	76
A.3	Tabulky pro metodu hranové reprezentace . . . . .	78
<b>B</b>	<b>Zdrojové kódy</b>	<b>79</b>
B.1	Výchozí nastavení vstupních proměnných . . . . .	79
B.2	Funkce pro celkovou analýzu . . . . .	80
B.2.1	Funkce pro značení cév . . . . .	82
B.3	Funkce pro vytvoření výsečí pro směrovou spektrální analýzu . . . . .	83
B.4	Funkce pro výpočet směrové spektrální analýzy . . . . .	84
B.5	Funkce pro výpočet metody založené na hranové reprezentaci . . . . .	85
B.6	Funkce pro výpočet analýzy jasu . . . . .	86
<b>C</b>	<b>Obrazová příloha</b>	<b>87</b>
C.1	Ukázka vzhledu hlavního menu navrženého programu . . . . .	87
C.2	Schéma programu pro RGB snímek . . . . .	88

# A Tabulky

## A.1 Tabulky pro cooc

Tab. A.1: Hodnoty průměrných energií vypočtených pomocí matic co - occurrence

Vzdálenost pix.		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
zdrave01																	
0°	1350.7	1236.9	1164.3	1116.4	1075.5	1013.2	960.27	886.53	839.62	792.58	763.26	703.17	665.44	604.83	553.68	915.0939	
45°	1229.2	1136.8	987.07	933.19	821.26	753.85	673.29	616.53	546.81	492.67	436.02	387.66	338.57	294.81	254.81	660.1693	
90°	1334	1210.5	1164.7	1091.9	1049.8	997.08	943.97	882.36	847.16	791.34	752.4	710.04	645.6	622.88	562.41	907.0780	
135°	1273.5	1095.3	1009.2	923.48	850.36	749.76	672.54	618.3	550.94	494	436.61	383.57	335.23	296.27	256.47	663.0339	
zdrave02																	
0°	1293.4	1187.8	1142.3	1071.3	1013.2	970.16	911.06	861.48	831.69	786.07	728	696.87	658.83	592.71	556.75	886.7792	
45°	1230.1	1062.1	977.81	876.74	801.28	741.63	684.33	609.14	541.17	482.4	429.08	390.69	342.09	298.67	261.7	648.5961	
90°	1312	1204	1173.3	1089.5	1023	963.31	917.82	857.41	826.58	771.72	742.55	689.8	639.85	605.11	546.8	890.8575	
135°	1205.6	1093.5	993.25	910.4	818.01	743.86	675.82	604.17	554.25	492.58	440.7	391.17	346.67	297.63	261.8	655.2975	
zdrave03																	
0°	1413.6	1256	1176.2	1096.8	1037.4	998.17	950.18	895.3	861.09	794.04	745.38	702.56	661.2	622.26	574.77	918.9978	
45°	1364	1162.3	1047.3	938.28	858.02	759.76	711.72	622.91	552.89	514.79	452.9	395.42	344.44	307.84	267.84	686.6916	
90°	1422.7	1266.4	1172.4	1104.1	1061.7	1012.3	942.66	890.18	852.88	814.91	752.69	693.84	671.4	612.3	573.84	922.9624	
135°	1262.3	1130.3	1027.3	947.47	849.96	767.36	689.95	619.68	559.58	499.23	450.44	394.55	348.89	303.59	266.21	674.4577	
zdrave04																	
0°	2106.5	1787.9	1567	1457.6	1386.7	1284.8	1247.9	1164.7	1074.3	994.57	951.62	887.74	816.73	745.56	697.96	1211.4	
45°	1731.7	1455.9	1318.3	1220.2	1092.4	976.39	886.63	805.88	738.69	647.69	575.56	502.6	441.72	385.6	325.33	873.6359	
90°	1958.1	1701.5	1529.2	1449.7	1418.4	1366.9	1256.1	1186	1118.5	1055.1	997.33	953.62	866.58	825.51	747.41	1228.7	
135°	1900.3	1543.7	1352.2	1218.6	1066	968.76	863.15	783.84	707.59	632.31	577.89	495.08	437.35	378.22	322.52	883.1706	
zdrave05																	
0°	2575.9	2338.9	2354.7	2064.8	1903.3	1813.4	1720.1	1562.4	1472.1	1412.8	1283.4	1184.9	1121.9	1013.5	885.43	1647.2	
45°	2320.7	2011.2	1924.7	1622.2	1459.8	1282.6	1144.5	970.6	891.71	758.11	662.61	587.52	496.85	421.49	361.96	1127.8	
90°	2801.5	2471.8	2299.9	2145.2	1979.4	1824.1	1726.3	1588.1	1477.8	1366.3	1244.2	1145.7	1025.8	951.72	871.18	1661.3	
135°	2416.9	2021.2	1862.9	1714.9	1413.1	1247.4	1175.8	1018.4	847.25	748.49	655.31	569.15	487.4	420.7	346.78	1129.7	
vypadek06																	
0°	1574.3	1436.3	1356.3	1257.5	1190.3	1133	1068.8	1007.1	962.33	901.75	859.14	784.79	715.17	675.18	613.67	1035.7	
45°	1462.9	1284.4	1129.2	1063	926.62	825.87	735.18	654.51	579.52	523.49	464.78	405.92	357.6	318.22	270.77	733.4682	
90°	1540.7	1409.4	1322.2	1248.6	1159.4	1104.4	1089	973.14	911.04	868.18	801.96	742.91	698.54	649.36	605.1	1008.3	
135°	1471.8	1286.5	1143.5	1035.4	909.54	802.99	723.14	677.43	584.9	526.47	462.21	408.24	360.16	312.9	269.36	731.6361	
vypadek07																	
0°	1512.2	1419.1	1303.2	1216.4	1175.5	1104.9	1047.8	1009.2	996.63	908.95	861.92	794.82	735.83	670.75	624.41	1025.4	
45°	1395.1	1267.2	1141.9	1055.6	926.44	847.91	773.23	703.4	602.54	535.89	487.5	414.51	362.72	326.02	281.18	741.4054	
90°	1523.7	1383	1302	1256	1218.9	1157.9	1051.8	1003.1	922.96	902.2	858.39	787.5	714.45	652.79	615.15	1023.3	
135°	1461	1268.4	1182.6	1025.3	914.07	825.62	750.01	678.14	608.76	542.08	473.51	418.08	375.48	324.44	279.48	741.7992	
vypadek08																	
0°	1502.9	1405.2	1313.6	1277.1	1198.9	1120.8	1066.2	1005.3	937.69	885.97	836.5	775.39	711.61	662.46	618.73	1021.2	
45°	1428	1278.3	1170	1042.6	917.12	847.03	761.29	679.43	588.48	538.55	469.52	413.73	365	309.07	272.22	738.6912	
90°	1469.5	1426.2	1319.5	1240.8	1180.9	1112.5	1042.6	965.59	926.33	873.47	806.7	771.04	707.66	675.01	617.98	1009.0	
135°	1453.2	1277.5	1153.8	1022.6	932.16	842.01	753.8	667.22	603.11	533.85	471.31	410.37	359.41	315.43	276.12	738.1319	
vypadek09																	
0°	2623.5	2307.3	2131.3	1978	1912.9	1862.9	1659	1528.6	1415.3	1323.2	1236.5	1200.2	1079.9	965.04	905.5	1093.3	
45°	2517.7	2138.7	1817.6	1550.6	1415.3	1218.6	1086.3	950.46	854.09	739.96	658.61	543.22	494.77	426.85	356.8	1118.0	
90°	2820.5	2354.1	2141.1	1967.1	1808.8	1658.2	1545.6	1458.6	1333.2	1242.4	1108.2	1052.4	988.72	904.01	835.25	1547.9	
135°	2361	2021.1	1782.8	1561.5	1451.1	1182.5	1041.3	950.22	825.01	744.04	640.37	552.16	494.38	422.59	369.71	1093.3	
vypadek10																	
0°	2340.4	2141.1	1899.3	1788.6	1666.2	1607.1	1523.7	1409.3	1311	1234.2	1169.4	1058.2	991.6	893.96	836.42	1458.0	
45°	2326.1	1971.3	1720.1	1462.7	1281.8	1155.1	1038	925.5	839.13	722.43	633.02	548.57	481.15	412.56	352.59	1058.0	
90°	2344.3	2069.3	1851.7	1726.7	1690.9	1611	1484.6	1387.5	1265.2	1192.7	1105.8	1051.3	953.92	874.16	808.94	1427.9	
135°	2143.6	1756.2	1665.3	1448.6	1278.9	1139	1002.8	910.39	806.68	691.3	621.14	550.12	478.13	409.83	356.36	1017.2	

Tab. A.2: Hodnoty entropií a kontrastů vypočtených pomocí matic co - occurrence

ENTROPIE	D	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
zdrave01	0°	-281.98	-239.36	-215.34	-203.53	-193.66	-177.77	-164.42	-143.14	-132.39	-121.63	-118.87	-102.69	-96.757	-79.554	-67.407	-155.9000
	45°	-235.36	-208.98	-161.78	-158.79	-125.55	-111.4	-92.284	-84.437	-67.235	-60.005	-47.327	-41.124	-32.98	-25.458	-19.626	-98.1555
	90°	-272.38	-223.33	-211.61	-191.71	-183.72	-169.89	-155.42	-137.54	-135.9	-120.27	-113.16	-106.52	-86.606	-87.56	-71.545	-151.1443
	135°	-254.4	-190.58	-172.44	-153.14	-134.84	-109.49	-92.166	-84.656	-69.72	-59.783	-48.909	-39.129	-30.296	-26.839	-21.067	-99.1644
zdrave05	0°	-765.31	-701.28	-691.19	-612.82	-560.93	-531.89	-499.12	-453.94	-422.82	-404.12	-363.36	-332.91	-312.42	-277.77	-236.67	-477.7702
	45°	-688.88	-600.46	-548.26	-474.55	-414.27	-361.43	-318.67	-263.98	-239.75	-196.3	-165.94	-145.19	-118.29	-94.547	-79.84	-314.0234
	90°	-809.07	-719.82	-670.77	-627.95	-577.39	-527.12	-496.9	-455.19	-416.91	-386.14	-347.74	-318.3	-278.39	-252.08	-227.83	-474.1077
	135°	-710.36	-604.1	-543.55	-499.04	-406.55	-351.52	-330.48	-276.56	-221.7	-189.89	-163.49	-140.02	-113.92	-96.755	-72.845	-314.7201
vypadek06	0°	-385.84	-335.43	-310.66	-278.5	-257.58	-240.26	-219.23	-204.44	-196.84	-180.22	-170.6	-149.49	-124.67	-119.85	-102.51	-218.4074
	45°	-343.47	-291.12	-238.82	-228.02	-180.54	-151.96	-126.64	-106.36	-86.647	-76.845	-65.692	-52.575	-43.847	-39.846	-29.92	-137.4864
	90°	-377.57	-329.13	-297.8	-271.1	-239.53	-227.5	-231.79	-187.64	-169.36	-161.48	-139.73	-126.18	-117.36	-103.91	-97.012	-205.1398
	135°	-349.65	-288.64	-247.88	-210.15	-172.53	-138.74	-120.56	-117.05	-90.698	-79.757	-63.959	-53.691	-45.942	-36.652	-28.804	-136.3136
vypadek07	0°	-361.77	-325.79	-285.72	-256.95	-251.67	-226.96	-213.29	-206.77	-209.92	-184.09	-175.73	-154.59	-138.99	-117.29	-106.97	-214.4351
	45°	-319.54	-282.18	-241.72	-220.74	-181.47	-164.21	-145.52	-132.88	-99.849	-84.291	-79.267	-57.633	-47.6	-44.072	-35.282	-142.4171
	90°	-368.19	-312.98	-289.26	-280.43	-272.8	-254.33	-215.37	-203.67	-177.3	-177.85	-170.44	-150.53	-126.32	-107.87	-101.59	-213.9284
	135°	-347.1	-282.48	-261.61	-209.4	-176.45	-153.02	-135.25	-119.65	-103.33	-87.572	-71.597	-60.206	-53.594	-43.382	-35.217	-142.6570
KONTRAST	D	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
zdrave02	0°	260640	376410	483300	549340	586200	592020	605560	595060	599540	607580	618470	636570	631600	617890	595300	557030
	45°	246190	347940	424180	472790	506250	509950	509350	493580	469740	444250	417450	395760	370600	338830	307280	416940
	90°	207470	237130	274690	316230	329880	349950	360650	361170	367650	373510	376190	374330	362670	354590	342750	332590
	135°	274060	387950	462570	480160	473340	437150	426560	427590	425510	428010	411570	377210	340860	304040	274070	395380
zdrave05	0°	69407	77811	88199	91053	97696	94074	93847	93084	93175	88797	85549	80454	78466	74891	71914	85228
	45°	85262	99313	104710	99010	94681	87038	83090	75339	71303	63817	59230	53453	45369	40105	35986	73181
	90°	81401	100520	108370	104200	103290	102740	98944	94338	90795	90208	86621	79330	74222	72490	66971	90296
	135°	82286	98052	96928	86578	79594	74182	71510	66827	63606	57574	51125	45319	41222	36925	33198	65662
vypadek06	0°	202290	226040	258420	264820	265800	244690	253140	242400	242290	236200	231320	219890	212490	197700	187040	232300
	45°	214340	242310	245820	235720	230450	213700	205350	182250	166630	155910	142520	128750	119330	109970	99125	179480
	90°	197470	220870	242340	256320	251820	245910	244930	238600	236090	221610	208680	205240	188720	177120	165160	220060
	135°	209400	237440	242590	237560	224070	201570	191630	174870	162900	152930	143080	125330	111290	96585	82999	172950
vypadek10	0°	61657	76219	90869	96537	100430	99919	103900	106060	107550	107260	105430	106060	109640	108540	107490	99170
	45°	64954	83132	93321	99791	104360	108860	111050	111630	111680	107910	101720	96212	89254	81419	72687	95864
	90°	61815	76888	93433	105400	117160	127970	133860	138510	142120	144170	146860	144370	143170	139220	136530	123430
	135°	70354	90040	102780	110990	115710	120490	120360	120970	121420	118430	113150	108020	100350	92294	83272	105910

## A.2 Rozdíly energií u spektrální analýzy

Tab. A.3: Maximální rozdíly energií u 22,5° výsečí 2D spekter testovacích textur z oblastí výpadku nervových vláken

Název textury	výpadek01	výpadek02	výpadek03	výpadek04	výpadek05	výpadek06	výpadek07	výpadek08	výpadek09	výpadek10
Přes excitační filtr,B složka	1,2242	1,0992	1,0574	1,199	1,0032	1,2751	1,1881	1,3289	0,4764	0,84
Přes excitační filtr,G složka	1,321	0,9386	1,0092	0,9684	0,8412	1,2311	0,8837	0,9813	0,6098	0,879
Přes excitační filtr,B složka,adapthisteq	1,6212	1,3234	1,3027	1,6545	1,3523	1,5981	1,4147	1,5838	0,6801	1,0566
Přes excitační filtr,G složka,adapthisteq	1,7516	1,0956	1,3105	1,2594	1,0547	1,5244	1,1992	1,2497	0,8662	1,0751
Název textury	výpadek11	výpadek12	výpadek13	výpadek14	výpadek15	výpadek16	výpadek17	výpadek18	výpadek19	výpadek20
Přes excitační filtr,B složka	0,7286	1,0345	0,7811	0,9311	1,2683	1,4276	1,4324	1,2168	0,9476	1,0508
Přes excitační filtr,G složka	1,073	0,8636	1,2964	1,3855	1,6544	1,4683	1,4892	1,2144	1,2804	1,1547
Přes excitační filtr,B složka,adapthisteq	0,8207	1,0549	0,9393	0,9831	1,4075	1,7502	1,6979	1,3242	1,1511	1,127
Přes excitační filtr,G složka,adapthisteq	1,2363	0,8593	1,5827	1,5063	1,7591	1,6819	1,7666	1,3551	1,5736	1,3523
Název textury	výpadek21	výpadek22	výpadek23	výpadek24	výpadek25	výpadek26	výpadek27	výpadek28	výpadek29	výpadek30
Přes excitační filtr,B složka	1,1571	1,2236	0,7346	0,8351	1,0022	0,9607	1,0437	1,3256	1,1427	1,1835
Přes excitační filtr,G složka	1,1265	1,4547	1,3118	0,9554	0,7748	0,7748	1,3054	0,9536	0,9627	0,7348
Přes excitační filtr,B složka,adapthisteq	1,411	1,4594	0,9185	1,0889	0,8525	1,0385	1,0124	1,4528	1,3747	1,4582
Přes excitační filtr,G složka,adapthisteq	1,3668	1,6877	1,6024	1,2878	0,6965	1,0726	1,2264	0,8929	1,3076	0,8122

Tab. A.4: Maximální rozdílly energií u 22,5° výsečí 2D spekter testovacích textur z oblastí zdravých tkání u nemocných očí

Název textury	zdr_vyp01	zdr_vyp02	zdr_vyp03	zdr_vyp04	zdr_vyp05	zdr_vyp06	zdr_vyp07	zdr_vyp08	zdr_vyp09	zdr_vyp10
Přes excitační filtr,B složka	2,2122	2,1661	2,0202	1,8641	1,8876	1,2544	1,468	1,9169	1,5824	1,5536
Přes excitační filtr,G složka	2,3336	2,2508	2,0226	1,9644	2,0133	1,4452	1,5769	2,0944	1,7422	1,8115
Přes excitační filtr,B složka,adapthisteq	2,7612	2,5689	2,4194	2,255	2,3425	1,613	1,8239	2,2846	1,9506	1,9161
Přes excitační filtr,G složka,adapthisteq	3,102	2,7661	2,4461	2,2584	2,4548	1,8063	1,9481	2,5379	2,1118	2,195
Název textury	zdr_vyp11	zdr_vyp12	zdr_vyp13	zdr_vyp14	zdr_vyp15	zdr_vyp16	zdr_vyp17	zdr_vyp18	zdr_vyp19	zdr_vyp20
Přes excitační filtr,B složka	1,0736	1,49	1,4963	1,2727	1,6773	1,7364	2,0962	1,6434	2,2718	1,9359
Přes excitační filtr,G složka	1,1833	1,7303	1,5491	1,2343	1,9713	2,153	2,071	2,0094	2,7131	2,3714
Přes excitační filtr,B složka,adapthisteq	1,3023	1,8403	1,5962	1,6602	1,8247	2,0547	2,6934	1,8779	2,7819	2,3467
Přes excitační filtr,G složka,adapthisteq	1,4444	2,0456	2,1067	1,4557	2,0186	2,5259	2,7631	2,3094	3,2318	1,9321
Název textury	zdr_vyp21	zdr_vyp22	zdr_vyp23	zdr_vyp24	zdr_vyp25	zdr_vyp26	zdr_vyp27	zdr_vyp28	zdr_vyp29	zdr_vyp30
Přes excitační filtr,B složka	1,4111	1,2023	1,5551	1,638	1,1882	1,8007	2,0392	1,8625	2,1601	1,6033
Přes excitační filtr,G složka	1,805	1,0362	1,4618	1,8596	1,4788	1,5187	2,3237	1,853	2,3007	1,6048
Přes excitační filtr,B složka,adapthisteq	1,6244	1,5842	1,8983	1,9671	1,4222	2,175	2,5292	2,1401	2,6443	1,9099
Přes excitační filtr,G složka,adapthisteq	2,2114	1,3242	1,9728	2,2191	1,7658	1,7225	2,8186	2,2437	2,7551	1,5232

Tab. A.5: Maximální rozdílly energií u 22,5° výsečí 2D spekter testovacích textur zdravých očí

Název textury	zdravé01	zdravé02	zdravé03	zdravé04	zdravé05	zdravé06	zdravé07	zdravé08	zdravé09	zdravé10
Přes excitační filtr,B složka	2,557	2,2641	2,3522	2,8009	1,7805	2,1272	2,2668	1,5662	1,7381	1,3381
Přes excitační filtr,G složka	2,4484	1,8323	2,827	2,8719	1,8567	2,116	2,3524	2,0164	1,8245	1,5436
Přes excitační filtr,B složka,adapthisteq	3,1364	2,7487	2,8143	3,3347	2,1505	2,5964	2,8318	1,9686	2,2284	1,6855
Přes excitační filtr,G složka,adapthisteq	3,1107	2,3409	3,3019	3,4303	2,1441	2,6749	2,8685	2,6195	2,2548	2,0346
Název textury	zdravé11	zdravé12	zdravé13	zdravé14	zdravé15	zdravé16	zdravé17	zdravé18	zdravé19	zdravé20
Přes excitační filtr,B složka	1,6115	1,8372	1,9911	2,0625	1,7166	1,9672	2,4274	2,1522	1,9809	1,8713
Přes excitační filtr,G složka	1,6293	1,7502	2,2425	2,0548	1,947	2,0763	2,4239	2,3168	2,5433	2,3975
Přes excitační filtr,B složka,adapthisteq	1,991	2,1058	2,3647	2,4954	2,0501	2,2989	2,8871	2,7906	2,5322	2,1353
Přes excitační filtr,G složka,adapthisteq	2,0916	2,1402	2,8273	2,5307	2,3122	2,5449	3,1206	3,0133	3,0329	2,6906
Název textury	zdravé21	zdravé22	zdravé23	zdravé24	zdravé25	zdravé26	zdravé27	zdravé28	zdravé29	zdravé30
Přes excitační filtr,B složka	1,0803	2,12	1,5181	1,5784	3,5646	2,4947	2,6521	2,591	2,4865	2,1071
Přes excitační filtr,G složka	1,19	2,2516	1,8657	1,5202	3,8273	2,3535	2,814	2,8318	2,853	2,1544
Přes excitační filtr,B složka,adapthisteq	0,9793	2,5835	1,8773	1,966	4,437	3,3476	3,3863	3,1285	2,9655	2,5229
Přes excitační filtr,G složka,adapthisteq	1,2059	2,5558	2,1914	1,6991	4,7007	3,2856	3,4958	3,3354	3,4147	2,6424

## A.3 Tabulky pro metodu hranové reprezentace

Tab. A.6: Počty pixelů detekovaných jako hrana u výřezů textur obsahujících výpadek ve vrstvě nervových vláken – skupina A

Název textury	výp01_1	výp02_1	výp03_1	výp04_1	výp05_1	výp06_2	výp07_2	výp08_2	výp09_3	výp10_3
B složka	303	248	111	235	127	332	261	320	57	136
G složka	270	31	42	0	27	42	24	18	107	121
Název textury	výp11_3	výp12_3	výp13_3	výp14_3	výp15_3	výp16_4	výp17_4	výp18_4	výp19_4	výp20_6
B složka	47	251	52	84	395	741	776	136	479	129
G složka	88	183	84	143	275	490	492	218	560	100
Název textury	výp21_6	výp22_6	výp23_6	výp24_6	výp25_7	výp26_7	výp27_7	výp28_7	výp29_7	výp30_7
B složka	64	297	123	132	296	285	502	322	322	261
G složka	73	254	172	66	283	142	356	235	280	222

Tab. A.7: Počty pixelů detekovaných jako hrana u tkání obsahujících nervová vlákna u nemocných očí – skupina B

Název textury	zdrVyp01_1	zdrVyp02_1	zdrVyp03_1	zdrVyp04_8	zdrVyp05_1	zdrVyp06_2	zdrVyp07_2	zdrVyp08_2	zdrVyp09_2	zdrVyp10_2
B složka	1156	881	770	1001	694	137	158	527	402	232
G složka	615	583	355	785	527	73	149	318	202	239
Název textury	zdrVyp11_3	zdrVyp12_3	zdrVyp13_3	zdrVyp14_3	zdrVyp15_3	zdrVyp16_4	zdrVyp17_4	zdrVyp18_4	zdrVyp19_4	zdrVyp20_4
B složka	407	543	641	600	707	448	530	496	522	1018
G složka	45	457	659	160	639	571	541	431	796	617
Název textury	zdrVyp21_6	zdrVyp22_6	zdrVyp23_6	zdrVyp24_6	zdrVyp25_6	zdrVyp26_7	zdrVyp27_7	zdrVyp28_7	zdrVyp29_7	zdrVyp30_7
B složka	385	363	393	484	347	755	996	503	983	746
G složka	432	201	337	509	244	822	751	528	748	358

Tab. A.8: Počty pixelů detekovaných jako hrana u tkání obsahujících nervová vlákna u zdravých očí – skupina C

Název textury	zdr01_8	zdr02_8	zdr03_8	zdr04_9	zdr05_9	zdr06_10	zdr07_10	zdr08_10	zdr09_11	zdr10_11
B složka	1615	1870	1862	2027	1524	1550	1436	543	1088	810
G složka	1564	1480	1770	1934	1352	1553	1283	906	1098	879
Název textury	zdr11_12	zdr12_12	zdr13_12	zdr14_13	zdr15_13	zdr16_13	zdr17_14	zdr18_14	zdr19_14	zdr20_15
B složka	970	966	1309	826	1003	717	1249	917	617	680
G složka	1072	773	1020	656	1140	836	1320	967	982	825
Název textury	zdr21_15	zdr22_16	zdr23_16	zdr24_16	zdr25_17	zdr26_175	zdr27_17	zdr28_18	zdr29_18	zdr30_18
B složka	268	1033	717	901	1934	1839	1747	1110	1297	1432
G složka	219	1069	434	972	2126	1784	1725	1052	1240	1457

## B Zdrojové kódy

### B.1 Výchozí nastavení vstupních proměnných

```
01 %----- Výchozí nastavení proměnných -----
02 krokovani_spektralni=16;           % Krok pro spektrální analýzu
03 krokovani_Log=16;                 % Krok pro analýzu založenou na hranové reprezentaci
04 krokovani_jas=16;                 % Krok pro analýzu jasu
05 pomer_bez_cev_spektralni=40;      % Hranice neurčitosti u spektrální analýzy [%]
06 pomer_bez_cev_jas=40;             % Hranice neurčitosti metody založené na hranové reprezentaci [%]
07 pomer_bez_cev_Log=40;             % Hranice neurčitosti u analýzy jasu [%]
08 R_cevy=64;                        % Velikost masky pro značení cév
09 cevy_vymaz_mensi_nez=250;         % Ve hranové reprezentaci cév vymazat objekty menší než
10 cevy_filtr_sigma=3.8;             % Sigma filtru č.2
11 cevy_filtr_ax=6;                  % ax filtru č.2
12 interpolace_dilatace=4;           % Počet kroků dilatace u vymaskování cév
13 interpolace_maska_prumerovani=64; % Maska u interpolace metodou průměrování
14 n=8;                              % Proměnná n spektrální analýzy
15 krok=7.5;                         % Proměnná krok spektrální analýzy
16 od=16;                            % Proměnná od spektrální analýzy
17 do=3;                             % Proměnná do spektrální analýzy
18 R_sp=64;                          % Proměnná R_sp spektrální analýzy = velikost masky
19 R_Log=64;                         % Velikost masky pro metodu založenou na hranové reprezentaci
20 R_jasu=3;                         % Velikost masky pro analýzu jasu
21 Log_zdrave_min=6;                % Minimální procento u hranové reprezentace pro zdravou tář
22 Log_vymaz_mensi_nez = 5;         % Vymazat hrany kratší než... u hranové reprezentace
23 vyrezy_zvetseni_optickeho_disku=30; % Zvětšení poloměru pro slepou skvrnu... pixelů při hledání ROI
24 vyrezy_posun_ROI_x=0;             % Posun ROI ve směru osy X
25 vyrezy_posun_ROI_y_kratsi=300;    % Nastavení ROI
26 vyrezy_posun_ROI_y_delsi=100;     % Nastavení ROI
27 vyrezy_sirka_ROI_x=700;           % Šířka ROI ve směru osy X
28 spektralni_hranice_zdrave=1.8;     % Hraniční hodnoty pro spektrální analýzu
29 spektralni_hranice_podezreni=1.65; % Hraniční hodnoty pro spektrální analýzu
30 spektralni_hranice_vypadku=1.5;    % Hraniční hodnoty pro spektrální analýzu
31 Log_hranice_podezreni = 95;        % Hraniční hodnoty pro metodu založenou na hranové reprezentaci
32 Log_hranice_vypadku = 95;         % Hraniční hodnoty pro metodu založenou na hranové reprezentaci
33 jas_hranice_zdrave = 7;           % Hraniční hodnoty pro analýzu jasu
34 jas_hranice_podezreni=12;         % Hraniční hodnoty pro analýzu jasu
35 jas_hranice_vypadku=17;          % Hraniční hodnoty pro analýzu jasu
```



## B.2 Funkce pro celkovou analýzu

```
01 function [BW_cevy,interpolovany_obraz,BW_maska,vystupni_obraz,vystupni_obraz_vysledek] = celkova_analyza(F1,vstupni_obraz,krokovani_spektralni,...
02   krokovani_Log,krokovani_jas,celkova_analyza_nastaveni_H5,celkova_analyza_nastaveni_H6,cevy_nastaveni_H11,cevy_nastaveni_H2,cevy_nastaveni_H3,...
03   vyrezy_zvetseni_optickeho_disku,vyrezy_posun_ROI_x,vyrezy_posun_ROI_y_kratsi,vyrezy_posun_ROI_y_delsi,vyrezy_sirka_ROI_x,spektralni_H2,...
04   R_cevy,R_sp,n,krok,od,do,R_jasu,R_Log,LoG_zdrave_min,LoG_vymaz_mensi_nez,LoG_H2,jas_H2,pomer_bez_cev_spektralni,pomer_bez_cev_Log,...
05   pomer_bez_cev_jas,LoG_hranice_podezreni,LoG_hranice_vypadku,spektralni_hranice_zdrave,spektralni_hranice_podezreni,spektralni_hranice_vypadku,...
06   cevy_vymaz_mensi_nez,cevy_filtr_ax,cevy_filtr_sigma,interpolace_dilatace,interpolace_maska_prumerovani,jas_hranice_zdrave,...
07   jas_hranice_podezreni,jas_hranice_vypadku,interpolace_nastaveni_H5,interpolace_nastaveni_H6)
08 set(0,'CurrentFigure',F1);
09 %----- Příprava výstupního souboru -----
10 [XX,YY,ZZ] = size(vstupni_obraz);
11 vstupni_upraveny=zeros(XX,YY,ZZ);
12 vstupni_upraveny=uint8(vstupni_upraveny);
13 if (get(celkova_analyza_nastaveni_H5,'Value') == 1) || (get(celkova_analyza_nastaveni_H6,'Value') == 1)
14     vstupni_upraveny(:,1) = round(vstupni_obraz(:,3)/2+vstupni_obraz(:,2)/2);
15     vstupni_upraveny(:,2)=vstupni_upraveny(:,1);
16     vstupni_upraveny(:,3)=vstupni_upraveny(:,1);
17     vstup.pokus1=vstupni_upraveny(:,1);
18     vstup.pokus2=vstupni_upraveny(:,1);
19     vstup.pokus3=vstupni_upraveny(:,1);
20 else
21     vstupni_upraveny(:,1)=vstupni_obraz;
22     vstupni_upraveny(:,2)=vstupni_obraz;
23     vstupni_upraveny(:,3)=vstupni_obraz;
24     vstup.pokus1=vstupni_obraz;
25     vstup.pokus2=vstupni_obraz;
26     vstup.pokus3=vstupni_obraz;
27 end
28 %----- Extrakce cév -----
29 BW_cevy = vessel01(vstupni_obraz,celkova_analyza_nastaveni_H5,celkova_analyza_nastaveni_H6,cevy_vymaz_mensi_nez,cevy_filtr_ax,...
30   cevy_filtr_sigma,cevy_nastaveni_H11,cevy_nastaveni_H2,cevy_nastaveni_H3);
31 axes('units','normalized','position',[.275 0.001 .45 .498]);
32 imshow(BW_cevy,[]);
33 %----- Vymaskování cév -----
34 interpolovany_obraz = interpolace_nejblihsi_soused(vstupni_obraz,BW_cevy,celkova_analyza_nastaveni_H5,celkova_analyza_nastaveni_H6,...
35   interpolace_dilatace,interpolace_maska_prumerovani,interpolace_nastaveni_H5,interpolace_nastaveni_H6);
36 axes('units','normalized','position',[.275 0.001 .45 .498]);
37 imshow(interpolovany_obraz,[])
38 %----- Výběr oblasti zájmu -----
39 [BW_maska,opticky_disk,xi,yi] = nalezeni_optickeho_disku(vstupni_obraz,vyrezy_zvetseni_optickeho_disku,vyrezy_posun_ROI_x,vyrezy_posun_ROI_y_kratsi,...
40   vyrezy_posun_ROI_y_delsi,vyrezy_sirka_ROI_x,spektralni_H2,celkova_analyza_nastaveni_H5,celkova_analyza_nastaveni_H6);
41 BW_maska=~BW_maska;
42 BW_maska=uint8(BW_maska);
43 set(0,'CurrentFigure',F1);
44 BW2 = bwmorph(BW_maska,'remove');
45 BW3 = bwmorph(BW2,'dilate',2);
46 BW2_epss = bwmorph(opticky_disk,'remove');
47 BW3_epss = bwmorph(BW2_epss,'dilate',2);
48 index1 = find(BW3 == 1);
49 vstup.pokus1(index1) = 255;
50 vstup.pokus2(index1) = 0;
51 vstup.pokus3(index1) = 255;
52 vstupni_upraveny(:,1)=vstup.pokus1;
53 vstupni_upraveny(:,2)=vstup.pokus2;
54 vstupni_upraveny(:,3)=vstup.pokus3;
55 set(0,'CurrentFigure',F1);
56 axes('units','normalized','position',[0.275 0.001 .45 .498]);
57 imshow(vstupni_upraveny,[]);
58 [XX,YY] = size(interpolovany_obraz);
59 matice_parametru=zeros(XX,YY);
60 min_x = ceil(min(xi));
61 max_x = ceil(max(xi));
62 min_y = ceil(min(yi));
63 max_y = ceil(max(yi));
64 BW_cevy = bwmorph(BW_cevy,'dilate',4);
65 BW_cevy_negativ=~BW_cevy;
66 BW_cevy_negativ=uint8(BW_cevy_negativ);
67 interpolovany_obraz_ROI=BW_maska.*interpolovany_obraz;
68 interpolovany_obraz_ROI=adapthisteq(interpolovany_obraz_ROI);
69 interpolovany_obraz_ROI=BW_maska.*interpolovany_obraz_ROI;
70 BW_cevy_vyrez=BW_cevy_negativ.*BW_maska;
71 %----- Označení cév -----
72 pomer_bez_cev(1,1)=pomer_bez_cev_spektralni;
73 pomer_bez_cev(1,2)=pomer_bez_cev_Log;
74 pomer_bez_cev(1,3)=pomer_bez_cev_jas;
```

```

75 pocet.analyz.pro.danny.pixel = zeros(XX,YY);
76 krokovani_min(1,1)=krokovani.spektralni;
77 krokovani_min(1,2)=krokovani.LoG;
78 krokovani_min(1,3)=krokovani.jas;
79 R.minimalni(1,1)=R.sp;
80 R.minimalni(1,2)=R.LoG;
81 R.min = min(R.minimalni);
82 [vystupni.obraz,vst.pom] = oznaceni.cev.pro.celkovou(vstupni.upraveny,BW.cevy.vyrez,interpolovany.obraz.ROI,krokovani_min,R.cevy,xi,yi,XX,YY,...
83     pomer.bez.cev,R.min);
84 %----- Spektrální analýza -----
85 spektralni.prepinac = get(spektralni.H2,'Value');
86 if spektralni.prepinac == 1
87     [vystupni.obraz,rozdil,matice.parametru,pocet.analyz.pro.danny.pixel] = spektralni.analyza.pro.celkovou(vst.pom,vystupni.obraz,BW.cevy.vyrez,...
88         interpolovany.obraz.ROI,krokovani.spektralni,pomer.bez.cev.spektralni,pocet.analyz.pro.danny.pixel,R.sp,n,krok,od,do,xi,yi,...
89         matice.parametru,XX,YY,pektralni.hranice.zdrave,pektralni.hranice.podezreni,pektralni.hranice.vypadku);
90 end
91 %----- Analýza zalozena na hranove reprezetaci -----
92 LoG.prepinac = get(LoG.H2,'Value');
93 if LoG.prepinac == 1
94     [vystupni.obraz,matice.parametru,pocet.analyz.pro.danny.pixel] = LoG.analyza.pro.celkovou(vst.pom,vystupni.obraz,BW.cevy.vyrez,...
95         interpolovany.obraz,krokovani.LoG,pomer.bez.cev.LoG,pocet.analyz.pro.danny.pixel,R.LoG,xi,yi,LoG.zdrave_min,LoG.vymaz.mensi.nez,...
96         matice.parametru,LoG.hranice.podezreni,LoG.hranice.vypadku);
97 end
98 %----- Analýza jasu -----
99 jas.prepinac = get(jas.H2,'Value');
100 if jas.prepinac == 1
101     [vystupni.obraz,matice.parametru,pocet.analyz.pro.danny.pixel] = analiza.jasu.pro.celkovou(vst.pom,vystupni.obraz,BW.cevy.vyrez,...
102         interpolovany.obraz.ROI,krokovani.jas,pocet.analyz.pro.danny.pixel,R.jasu,xi,yi,pomer.bez.cev.jas,XX,YY,matice.parametru,R.min,...
103         jas.hranice.zdrave,jas.hranice.podezreni,jas.hranice.vypadku);
104 end
105 %----- Značení všech tří analýz -----
106 for mm = min.x:min(krokovani_min):max.x
107     for nn = min.y:min(krokovani_min):max.y
108         if BW.cevy.vyrez(mm,nn) == true && vst.pom(mm,nn)==1 && (sum(sum(~BW.cevy.vyrez(mm-R.cevy:mm+R.cevy-1,nn-R.cevy:nn+R.cevy-1))))...
109             < round((R.cevy*2*R.cevy*2)*max(pomer.bez.cev))
110             if pocet.analyz.pro.danny.pixel(mm,nn) == 1
111                 if matice.parametru(mm,nn) > 1
112                     vystupni.obraz(mm:mm+1,nn:nn+1,1)=0;
113                     vystupni.obraz(mm:mm+1,nn:nn+1,2)=255;
114                     vystupni.obraz(mm:mm+1,nn:nn+1,3)=0;
115                 else
116                     vystupni.obraz(mm:mm+1,nn:nn+1,1)=255;
117                     vystupni.obraz(mm:mm+1,nn:nn+1,2)=0;
118                     vystupni.obraz(mm:mm+1,nn:nn+1,3)=0;
119                 end
120             end
121             if pocet.analyz.pro.danny.pixel(mm,nn) == 2
122                 if matice.parametru(mm,nn) > 2
123                     vystupni.obraz(mm:mm+1,nn:nn+1,1)=0;
124                     vystupni.obraz(mm:mm+1,nn:nn+1,2)=255;
125                     vystupni.obraz(mm:mm+1,nn:nn+1,3)=0;
126                 else
127                     vystupni.obraz(mm:mm+1,nn:nn+1,1)=255;
128                     vystupni.obraz(mm:mm+1,nn:nn+1,2)=0;
129                     vystupni.obraz(mm:mm+1,nn:nn+1,3)=0;
130                 end
131             end
132             if pocet.analyz.pro.danny.pixel(mm,nn) == 3
133                 if matice.parametru(mm,nn) > 4
134                     vystupni.obraz(mm:mm+1,nn:nn+1,1)=0;
135                     vystupni.obraz(mm:mm+1,nn:nn+1,2)=255;
136                     vystupni.obraz(mm:mm+1,nn:nn+1,3)=0;
137                 else
138                     vystupni.obraz(mm:mm+1,nn:nn+1,1)=255;
139                     vystupni.obraz(mm:mm+1,nn:nn+1,2)=0;
140                     vystupni.obraz(mm:mm+1,nn:nn+1,3)=0;
141                 end
142             end
143         end
144     end
145 end
146 %----- Značení celkové analýzy -----
147 if (get(celkova.analyza.nastaveni.H5,'Value') == 1) || (get(celkova.analyza.nastaveni.H6,'Value') == 1)
148     vystupni.obraz.vysledek=zeros(XX,YY,3);
149     vystupni.obraz.vysledek(:, :, 1) = round(vstupni.obraz(:, :, 3)/2+vstupni.obraz(:, :, 2)/2);
150     vystupni.obraz.vysledek(:, :, 2)=vystupni.obraz.vysledek(:, :, 1);
151     vystupni.obraz.vysledek(:, :, 3)=vystupni.obraz.vysledek(:, :, 1);
152 else
153     vystupni.obraz.vysledek=zeros(XX,YY,3);

```

```

154     vystupni_obraz_vysledek=uint8(vystupni_obraz_vysledek);
155     vystupni_obraz_vysledek(:,:,1)=vstupni_obraz;
156     vystupni_obraz_vysledek(:,:,2)=vstupni_obraz;
157     vystupni_obraz_vysledek(:,:,3)=vstupni_obraz;
158 end
159 for mm = min_x:min(krokovani_min):max_x
160     for nn = min_y:min(krokovani_min):max_y
161         if BW_cevy_vyrez(mm,nn) == false && vst_pom(mm,nn)==1
162             vystupni_obraz_vysledek(mm-krokovani_min/2:mm+krokovani_min/2-1,nn-krokovani_min/2:nn+krokovani_min/2-1,3)=vystupni_obraz_vysledek(mm,nn,3)+30;
163         elseif BW_cevy_vyrez(mm,nn) == true && (sum(sum(~BW_cevy_vyrez(mm-R_cevy:mm+R_cevy-1,nn-R_cevy:nn+R_cevy-1)))) > round((R_cevy*2+R_cevy*2)*...
164             max(pomer_bez_cevy)) && vst_pom(mm,nn)==1
165             vystupni_obraz_vysledek(mm-krokovani_min/2:mm+krokovani_min/2-1,nn-krokovani_min/2:nn+krokovani_min/2-1,2)=vystupni_obraz_vysledek(mm,nn,2)+30;
166             vystupni_obraz_vysledek(mm-krokovani_min/2:mm+krokovani_min/2-1,nn-krokovani_min/2:nn+krokovani_min/2-1,3)=vystupni_obraz_vysledek(mm,nn,3)+30;
167         elseif BW_cevy_vyrez(mm,nn) == true && vst_pom(mm,nn)==1 && (sum(sum(~BW_cevy_vyrez(mm-R_cevy:mm+R_cevy-1,nn-R_cevy:nn+R_cevy-1))))...
168             < round((R_cevy*2+R_cevy*2)*max(pomer_bez_cevy))
169             if pocet_analyz_pro_danny_pixel(mm,nn) == 1
170                 if matice_parametru(mm,nn) > 1
171                     vystupni_obraz_vysledek(mm-krokovani_min/2:mm+krokovani_min/2-1,nn-krokovani_min/2:nn+krokovani_min/2-1,2)=vystupni_obraz_vysledek(mm,nn,2)+30;
172                 else
173                     vystupni_obraz_vysledek(mm-krokovani_min/2:mm+krokovani_min/2-1,nn-krokovani_min/2:nn+krokovani_min/2-1,1)=vystupni_obraz_vysledek(mm,nn,1)+30;
174                 end
175             end
176             if pocet_analyz_pro_danny_pixel(mm,nn) == 2
177                 if matice_parametru(mm,nn) > 2
178                     vystupni_obraz_vysledek(mm-krokovani_min/2:mm+krokovani_min/2-1,nn-krokovani_min/2:nn+krokovani_min/2-1,2)=vystupni_obraz_vysledek(mm,nn,2)+30;
179                 else
180                     vystupni_obraz_vysledek(mm-krokovani_min/2:mm+krokovani_min/2-1,nn-krokovani_min/2:nn+krokovani_min/2-1,1)=vystupni_obraz_vysledek(mm,nn,1)+30;
181                 end
182             end
183             if pocet_analyz_pro_danny_pixel(mm,nn) == 3
184                 if matice_parametru(mm,nn) > 4
185                     vystupni_obraz_vysledek(mm-krokovani_min/2:mm+krokovani_min/2-1,nn-krokovani_min/2:nn+krokovani_min/2-1,2)=vystupni_obraz_vysledek(mm,nn,2)+30;
186                 else
187                     vystupni_obraz_vysledek(mm-krokovani_min/2:mm+krokovani_min/2-1,nn-krokovani_min/2:nn+krokovani_min/2-1,1)=vystupni_obraz_vysledek(mm,nn,1)+30;
188                 end
189             end
190         end
191     end
192 end
193 axes('units','normalized','position',[.275 0.001 .45 .498]);
194 imshow(vystupni_obraz_vysledek,[]);
195 figure; imshow(vystupni_obraz,[]);
196 figure; imshow(vystupni_obraz_vysledek,[]);

```

## B.2.1 Funkce pro značení cév

```

01 function [vystupni_obraz,vst_pom] = oznaceni_cev_pro_celkovou(vstupni_upraveny,BW_cevy_vyrez,interpolovany_obraz_ROI,krokovani_min,R_cevy,xi,yi,XX,...
02     YY,pomer_bez_cevy,R_min)
03 vystupni_obraz=vstupni_upraveny;
04 min_x = ceil(min(xi));
05 max_x = ceil(max(xi));
06 min_y = ceil(min(yi));
07 max_y = ceil(max(yi));
08 vst_pom=false(XX,YY);
09 krok_min = min(krokovani_min);
10 hhhh = waitbar(0,'Probíhá značení cév...');
11 for mm = min_x:krok_min:max_x
12     for nn = min_y:krok_min:max_y
13         if interpolovany_obraz_ROI(mm-R_min:mm+R_min,nn-R_min:nn+R_min) > 0
14             vst_pom(mm,nn)=true;
15         end
16         if BW_cevy_vyrez(mm,nn) == false && vst_pom(mm,nn)==1
17             vystupni_obraz(mm-1:mm+1,nn-1:nn+1,1)=0;
18             vystupni_obraz(mm-1:mm+1,nn-1:nn+1,2)=0;
19             vystupni_obraz(mm-1:mm+1,nn-1:nn+1,3)=255;
20         elseif BW_cevy_vyrez(mm,nn) == true && (sum(sum(~BW_cevy_vyrez(mm-R_cevy:mm+R_cevy-1,nn-R_cevy:nn+R_cevy-1))))...
21             > round((R_cevy*2+R_cevy*2)*max(pomer_bez_cevy)) && vst_pom(mm,nn)==1
22             vystupni_obraz(mm-1:mm+1,nn-1:nn+1,1)=0;
23             vystupni_obraz(mm-1:mm+1,nn-1:nn+1,2)=255;
24             vystupni_obraz(mm-1:mm+1,nn-1:nn+1,3)=255;
25         end
26     end
27 waitbar(mm/(max_x-min_x))
28 end
29 close(hhhh)

```

## B.3 Funkce pro vytvoření výsečí pro směrovou spektrální analýzu

```
01 function [pole_masek,pocet_kroku] = spektralni_analyza_vysece(R_sp,n,krok,od,do)
02 stred_x=R_sp+1;
03 stred_y=stred_x;
04 uhel=180/n;
05 anglout = deg2rad(uhel);
06 pocet_kroku = (180/krok) - (uhel/krok) + 1;
07 %----- Cyklus pro vytvoření hraničních pixelů pro jednu výseč -----
08 for a = 0:pocet_kroku
09     otoceni = krok*a;
10     uhel1 = deg2rad(uhel+otoceni);
11     [X1,Y1] = pol2cart(uhel1,64);
12     XX1 = X1+R_sp+1;
13     YY1 = Y1+R_sp+1;
14     c1{1,a+1} = round(XX1);
15     r1{1,a+1} = round(YY1) ;
16
17     [X2,Y2] = pol2cart(uhel1-anglout,64);
18     XX2 = X2+R_sp+1;
19     YY2 = Y2+R_sp+1;
20     c2{1,a+1} = round(XX2);
21     r2{1,a+1} = round(YY2);
22 end
23 delka_strany = R_sp*2+1;
24 eps(1:delka_strany,1:delka_strany) = 0;
25 init_x = stred_x-R_sp;
26 init_y = init_x;
27 %----- Cyklus pro vytvoření mezikruží -----
28 for i = 1:delka_strany
29     for j = 1:delka_strany
30         dist = ((init_x+i)-stred_x)^2+((init_y+j)-stred_y)^2;
31         dist = sqrt(dist);
32         dist = ceil(dist);
33         if dist < (R_sp/do) && dist > (R_sp/od)
34             eps(init_x+i, init_y+j) = 1;
35         end
36     end
37 end
38 pomocna = zeros(delka_strany,delka_strany);
39 pole_masek = zeros(delka_strany,delka_strany,pocet_kroku);
40 %----- Cyklus pro vytvoření výsledné výseče -----
41 for e = 1:pocet_kroku
42     c=[stred_x c1{1,e} c2{1,e} stred_x];
43     r=[stred_x r1{1,e} r2{1,e} stred_x];
44     BWw = roipoly(pomocna,c,r);
45     BWw = double(BWw);
46     BW = BWw.*eps;
47     BW(:,stred_x)=0;
48     pole_masek(:,:,e)=BW;
49 end
```

## B.4 Funkce pro výpočet směrové spektrální analýzy

```

01 function [vystupni_obraz, rozdil, matice_parametru, pocet_analyz_pro_danny_pixel] = spektralni_analyza_pro_celkovou(vst_pom, vystupni_obraz, ...
02     BW_cevy_vyrez, interpolovany_obraz_ROI, krokovani_spektralni, pomer_bez_cev_spektralni, pocet_analyz_pro_danny_pixel, R, n, krok, od, do, xi, yi, ...
03     matice_parametru, XX, YY, spektralni_hranice_zdrave, spektralni_hranice_podezreni, spektralni_hranice_vypadku)
04 min_x = ceil(min(xi));
05 max_x = ceil(max(xi));
06 min_y = ceil(min(yi));
07 max_y = ceil(max(yi));
08 pomer_bez_cev_spektralni = pomer_bez_cev_spektralni / 100;
09 %----- Funkce pro výpočet výsečí -----
10 [pole_masek, pocet_kroku] = spektralni_analyza_vysece(R, n, krok, od, do);
11 %----- Cyklus pro zjištění počtu pixelů v jednotlivých výsečích -----
12 for e = 1:pocet_kroku
13     k=0;
14     for o = 1:2*R
15         for p = 1:2*R
16             if pole_masek(o,p,e) == 1
17                 k=k+1;
18             end
19         end
20     end
21     pocet(e) = k;
22 end
23 rozdil = zeros(XX,YY);
24 cekaci_lista = waitbar(0, 'Probíhá spektrální analýza...');
25 %----- Cyklus výpočtu spektrální analýzy a vyznačení výsledků -----
26 for mm = min_x+R:krovani_spektralni:max_x-R
27     for nn = min_y+R:krovani_spektralni:max_y-R
28         if BW_cevy_vyrez(mm,nn) == true && vst_pom(mm,nn)==1 && (sum(sum(~BW_cevy_vyrez(mm-R:mm+R-1,nn-R:nn+R-1))))...
29             < round((R*2*R*2)*pomer_bez_cev_spektralni)
30             pocet_analyz_pro_danny_pixel(mm,nn) = pocet_analyz_pro_danny_pixel(mm,nn) + 1;
31             Image = interpolovany_obraz_ROI(mm-R:mm+R,nn-R:nn+R);
32             spektrum = fft2(double(Image));
33             amplitudove_spektrum = fftshift(log10(abs(spektrum)));
34             for e = 1:pocet_kroku
35                 pole_spekter(:, :, e) = pole_masek(:, :, e).*amplitudove_spektrum;
36                 energie(:, :, e) = pole_spekter(:, :, e).^2;
37                 celkova_energie = sum(sum(energie(:, :, e)));
38                 prumer_na_energie(e) = celkova_energie/pocet(e);
39                 rozdil(mm,nn) = max(prumer_na_energie(:)) - min(prumer_na_energie(:));
40                 rozdil(mm-(krovani_spektralni/2):mm+(krovani_spektralni/2)-1,nn-(krovani_spektralni/2):...
41                     nn+(krovani_spektralni/2)-1)=rozdil(mm,nn);
42                 if rozdil(mm,nn) < spektralni_hranice_vypadku
43                     vystupni_obraz(mm-1,nn-1,1)=255;
44                     vystupni_obraz(mm-1,nn-1,2)=0;
45                     vystupni_obraz(mm-1,nn-1,3)=0;
46                 end
47                 if rozdil(mm,nn) > spektralni_hranice_zdrave
48                     vystupni_obraz(mm-1,nn-1,1)=0;
49                     vystupni_obraz(mm-1,nn-1,2)=255;
50                     vystupni_obraz(mm-1,nn-1,3)=0;
51                     matice_parametru(mm,nn)=3;
52                 end
53                 if rozdil(mm,nn) > spektralni_hranice_podezreni && rozdil(mm,nn) < spektralni_hranice_zdrave
54                     vystupni_obraz(mm-1,nn-1,1)=255;
55                     vystupni_obraz(mm-1,nn-1,2)=255;
56                     vystupni_obraz(mm-1,nn-1,3)=0;
57                     matice_parametru(mm,nn)=2;
58                 end
59                 if rozdil(mm,nn) > spektralni_hranice_vypadku && rozdil(mm,nn) < spektralni_hranice_podezreni
60                     vystupni_obraz(mm-1,nn-1,1)=255;
61                     vystupni_obraz(mm-1,nn-1,2)=158;
62                     vystupni_obraz(mm-1,nn-1,3)=102;
63                     matice_parametru(mm,nn)=1;
64                 end
65             end
66         end
67     end
68 waitbar(mm/max_x)
69 end
70 close(cekaci_lista)

```

## B.5 Funkce pro výpočet metody založené na hranové reprezentaci

```

01 function [vystupni_obraz,matice_parametru,pocet_analyz_pro_danny_pixel] = LoG_analyza_pro_celkovou...
02     (vst_pom,vystupni_obraz,BW_cevy_vyrez,interpolovany_obraz,krokovani_Log,pomer_bez_cev_Log,...
03     pocet_analyz_pro_danny_pixel,R_Log,xi,yi,LoG_zdrave_min,LoG_vymaz_mensi_nez,matice_parametru,...
04     LoG_hranice_podezreni,LoG_hranice_vypadku)
05
06 LoG_hranice_podezreni = LoG_hranice_podezreni / 100;
07 LoG_hranice_vypadku = LoG_hranice_vypadku / 100;
08 pomer_bez_cev_Log = pomer_bez_cev_Log / 100;
09
10 min_x = ceil(min(xi));
11 max_x = ceil(max(xi));
12 min_y = ceil(min(yi));
13 max_y = ceil(max(yi));
14 %----- Pro správné nastavení prahu u LoG detektoru je nutno se znavit černých okrajů snímku = udělat výřez -----
15 vst = interpolovany_obraz(min_x:max_x,min_y:max_y);
16 [X,Y] = size(interpolovany_obraz);
17 %----- Detekce hran založená na LoG hranovém operátoru -----
18 LoG_detekce = edge(vst,'log');%7e-004);
19 %----- Odstranění drobných objektů -----
20 LoG_detekce_upravena = bwareaopen(LoG_detekce,LoG_vymaz_mensi_nez);
21 LoG_detekce_upravena_ROI = zeros(X,Y);
22 LoG_detekce_upravena_ROI(min_x:max_x,min_y:max_y) = LoG_detekce_upravena;
23 LoG_detekce_upravena_ROI = logical(LoG_detekce_upravena_ROI);
24 BW_cevy_vyrez = logical(BW_cevy_vyrez);
25 LoG_detekce_upravena_ROI_minus_cevy = BW_cevy_vyrez.*LoG_detekce_upravena_ROI;
26 max_pocet_bodu = R_Log*2*R_Log*2;
27 pocet_pro_zdravou_tkan_min = max_pocet_bodu * (LoG_zdrave_min / 100);
28 pocet_v_ROI = zeros(max_x,max_y);
29 %----- Cyklus pro výpočet výsledků detekce, značení výsledků -----
30 cekaci_lista = waitbar(0,'Prosim čekejte, probíhá LoG analýza...');
31 for mm = min_x+R_Log:krokovani_Log:max_x-R_Log
32     for nn = min_y+R_Log:krokovani_Log:max_y-R_Log
33         if BW_cevy_vyrez(mm,nn) == true && (sum(sum(~BW_cevy_vyrez(mm-R_Log:mm+R_Log-1,nn-R_Log:...
34             nn+R_Log-1)))) < round((R_Log*2*R_Log*2)*pomer_bez_cev_Log) && vst_pom(mm,nn)==1
35             pocet_analyz_pro_danny_pixel(mm,nn) = pocet_analyz_pro_danny_pixel(mm,nn) + 1;
36             Image = LoG_detekce_upravena_ROI_minus_cevy(mm-R_Log:mm+R_Log-1,nn-R_Log:nn+R_Log-1);
37             pocet_bodu = (sum(sum(BW_cevy_vyrez(mm-R_Log:mm+R_Log-1,nn-R_Log:nn+R_Log-1))));
38             pomer_bodu = pocet_bodu / max_pocet_bodu;
39             zdrave = pocet_pro_zdravou_tkan_min * pomer_bodu;
40             pocet_v_ROI(mm,nn) = sum(sum(Image(:,:)));
41             if pocet_v_ROI(mm,nn) > (zdrave*LoG_hranice_podezreni) && pocet_v_ROI(mm,nn) < zdrave
42                 vystupni_obraz(mm-1,nn+1,1)=255;
43                 vystupni_obraz(mm-1,nn+1,2)=255;
44                 vystupni_obraz(mm-1,nn+1,3)=0;
45                 matice_parametru(mm,nn)=matice_parametru(mm,nn)+2;
46             end
47             if pocet_v_ROI(mm,nn) > zdrave
48                 vystupni_obraz(mm-1,nn+1,1)=0;
49                 vystupni_obraz(mm-1,nn+1,2)=255;
50                 vystupni_obraz(mm-1,nn+1,3)=0;
51                 matice_parametru(mm,nn)=matice_parametru(mm,nn)+3;
52             end
53             if pocet_v_ROI(mm,nn) < (zdrave*(LoG_hranice_podezreni*LoG_hranice_vypadku))
54                 vystupni_obraz(mm-1,nn+1,1)=255;
55                 vystupni_obraz(mm-1,nn+1,2)=0;
56                 vystupni_obraz(mm-1,nn+1,3)=0;
57             % binarni_obraz(mm,nn)= 2;
58             end
59             if pocet_v_ROI(mm,nn) > (zdrave*(LoG_hranice_podezreni*LoG_hranice_vypadku))...
60                 && pocet_v_ROI(mm,nn) < (zdrave*LoG_hranice_podezreni)
61                 vystupni_obraz(mm-1,nn+1,1)=255;
62                 vystupni_obraz(mm-1,nn+1,2)=158;
63                 vystupni_obraz(mm-1,nn+1,3)=102;
64                 matice_parametru(mm,nn)=matice_parametru(mm,nn)+1;
65             end
66         end
67     end
68 end
69 waitbar(mm/max_x)
70 end
71 close(cekaci_lista)


```

## B.6 Funkce pro výpočet analýzy jasu

```
01 function [vystupni_obraz,matice_parametru,pocet_analyz_pro_danny_pixel] = analiza_jasu_pro_celkovou(vst_pom,vystupni_obraz,BW_cevy_vyrez,...
02     interpolovany_obraz_ROI,krokovani_jas,pocet_analyz_pro_danny_pixel,R_jasu,xi,yi,pomer_bez_cev_jas,XX,YY,matice_parametru,R_min,...
03     jas_hranice_zdrave,jas_hranice_podezreni,jas_hranice_vypadku)
04 pomer_bez_cev_jas = pomer_bez_cev_jas /100;
05
06 min_x = ceil(min(xi));
07 max_x = ceil(max(xi));
08 min_y = ceil(min(yi));
09 max_y = ceil(max(yi));
10
11 obraz_bez_cev=interpolovany_obraz_ROI.*BW_cevy_vyrez;
12
13 soucet = sum(obraz_bez_cev(:))
14 pocet_bodu = sum(sum(BW_cevy_vyrez))
15 prumerny_jas = soucet / pocet_bodu
16 %----- Cyklus pro výpočet analýz jasu, značení výsledků -----
17 prumerny_bod = zeros(XX,YY);
18 hhhh = waitbar(0,'Prosim čekejte, probíhá analýza jasu...');
19 for mm = min_x+R_min:krokovani_jas:max_x-R_min
20     for nn = min_y+R_min:krokovani_jas:max_y-R_min
21         if BW_cevy_vyrez(mm,nn) == true && vst_pom(mm,nn)==1 && (sum(sum(~BW_cevy_vyrez(mm-R_min:mm+R_min-1,nn-R_min:nn+R_min-1))))...
22             < round((R_min*2*R_min*2)*pomer_bez_cev_jas)
23             pocet_analyz_pro_danny_pixel(mm,nn) = pocet_analyz_pro_danny_pixel(mm,nn) + 1;
24             prumerny_bod(mm,nn) = sum(sum(interpolovany_obraz_ROI(mm-R_jasu:mm+R_jasu-1,nn-R_jasu:nn+R_jasu-1)))/(R_jasu*2*R_jasu*2);
25             if prumerny_bod(mm,nn) < (prumerny_jas-jas_hranice_vypadku)
26                 vystupni_obraz(mm+1,nn-1,1)=255;
27                 vystupni_obraz(mm+1,nn-1,2)=0;
28                 vystupni_obraz(mm+1,nn-1,3)=0;
29             elseif prumerny_bod(mm,nn) < (prumerny_jas-jas_hranice_podezreni)
30                 vystupni_obraz(mm+1,nn-1,1)=255;
31                 vystupni_obraz(mm+1,nn-1,2)=158;
32                 vystupni_obraz(mm+1,nn-1,3)=102;
33                 matice_parametru(mm,nn)=matice_parametru(mm,nn)+1;
34             elseif prumerny_bod(mm,nn) < (prumerny_jas-jas_hranice_zdrave)
35                 vystupni_obraz(mm+1,nn-1,1)=255;
36                 vystupni_obraz(mm+1,nn-1,2)=255;
37                 vystupni_obraz(mm+1,nn-1,3)=0;
38                 matice_parametru(mm,nn)=matice_parametru(mm,nn)+2;
39             else
40                 vystupni_obraz(mm+1,nn-1,1)=0;
41                 vystupni_obraz(mm+1,nn-1,2)=255;
42                 vystupni_obraz(mm+1,nn-1,3)=0;
43                 matice_parametru(mm,nn)=matice_parametru(mm,nn)+3;
44             end
45         end
46     end
47     waitbar(mm/max_x)
48 end
49 close(hhhh)
```

# C    Obrazová příloha

## C.1   Ukázka vzhledu hlavního menu navrženého programu





## C.2 Schéma programu pro RGB snímek

